

SVEUČILIŠTE U ZAGREBU
FAKULTET STROJARSTVA I BRODOGRADNJE

**POSLOVNA INTELIGENCIJA U GOSPODARENJU
TEHNIČKIM SUSTAVIMA**

MAGISTARSKI RAD

Mentor

dr. sc. IVO ČALA

BRANIMIR PREPROTIĆ

ZAGREB, 2006

PODACI ZA BIBLIOGRAFSKU KARTICU

UDK: 658.511.5

007:658.5

Ključne riječi: Gospodarenje tehničkim sustavima, Gospodarenje materijalnom imovinom, Poslovna inteligencija, Skladište podataka, Bayesova mreža povjerenja, Model donošenja odluka

Znanstveno područje: Tehničke znanosti

Znanstveno polje: Strojarsstvo

Institucija u kojoj je rad izrađen: Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu

Mentor rada: dr. sc. Ivo Čala, izv. profesor

Broj stranica: 111

Broj slika: 23

Broj tablica: 7

Broj korištenih bibliografskih jedinica: 31

Datum obrane: 10. 01. 2006.

Povjerenstvo: dr. sc. Čedomir Oluić, red. profesor
dr. sc. Ivo Čala, prof, izv. profesor
dr. sc. Niko Majdandžić, red. profesor, Strojarski fakultet u Slavonskom Brodu

Institucija u kojoj je rad pohranjen: Fakultet strojarstva i brodogradnje, Zagreb



Zagreb, 2005-06-27

Zadatak za magistarski rad

Kandidat: *Branimir Preprotić, dipl. ing. strojarstva*

Naslov zadatka: **Poslovna inteligencija u gospodarenju tehničkim sustavima**

Sadržaj zadatka:

Pouzdanost, raspoloživost i efikasnost tehničkih sustava osigurana je nekim od postojećih pristupa u održavanju. U većim tvrtkama održavatelji nisu uključeni u donošenje strateških odluka, što znači da informacija o stanju tehničkih sustava nije uključena u takve odluke, a niti održavatelji nisu informirani o strategiji i trendovima u okruženju. Takva situacija može rezultirati neoptimalnom dodjelom prioriteta kod značajnijih zahvata održavanja ili manjih investicija. Sustav kojim je moguće izbjeći takvu situaciju je poslovna inteligencija podržana nekim od brojnih IT alata.

U radu je potrebno:

- dati kratki pregled suvremenih koncepata održavanja i gospodarenja materijalnom imovinom
- pojasniti pojam poslovne inteligencije u tvrtki

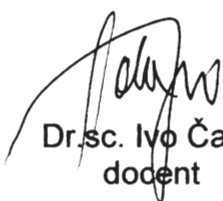
Na primjeru jedne veće tvrtke potrebno je:

- provesti istraživanje o stavovima i mišljenjima višeg menadžmenta o funkciji održavanja
- predložiti model pristupa gospodarenja tehničkim sustavima koristeći informacije dostupne kroz primjenu poslovne inteligencije
- kroz studije slučaja ispitati koristi primjene poslovne inteligencije u gospodarenju tehničkim sustavima

Zadatak zadan: 12.07.2005.

Rad predan:

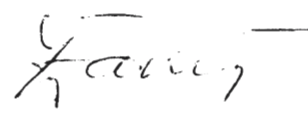
Mentor:


Dr. sc. Ivo Čala,
docent


Predsjednik Odbora za
poslijediplomske studije:

Dr. sc. Branko Novaković,
red. prof.

Voditelj smjera:


Dr. sc. Nikola Šakić,
red. prof.

ZAHVALA

"Najteže breme je ono koje čovjek nosi sam". Negdje sam čuo ovu izreku, ali nažalost nije mi poznato njezino porijeklo. U raznim fazama pomogli su mi kolege, prijatelji a posebno mentor. Krenut ću kronološkim redoslijedom i nadam se da nikoga neću izostaviti. Za moj upis na poslijediplomski studij i snošenje troškova od strane Plive d.d. posebnu zahvalnost dugujem g. Dragi Frkoviću i g. Tomislavu Šarčeviću. Bez njihovog razumijevanja i osobnog doprinosa moj upis na poslijediplomski studij ne bi bio moguć. Kod polaganja ispita, seminara i izrade rada uvijek mi je bio omogućen slobodan dan ili sat, a za to neizmjernu zahvalnost dugujem direktorici Boženi Klepić, koja je osim navedene konkretne podrške pružala i moralnu kada je to bilo najpotrebnije.

U trenucima kada je moje "znanstveno breme" postajalo preteško te sam ga poželio odbaciti, velike zasluge što do toga nije došlo ima moja draga prijateljica Ivana Širić. Posebnu zahvalnost dugujem Suzani koja je bila uz mene i neizmjereno puno mi pomogla svojom podrškom i razumijevanjem.

I na kraju osoba koja me je cijelo vrijeme vodila i pružala mi podršku i uporište ne samo u znanstvenoj i stručnoj domeni već i u ljudskoj je moj mentor dr. Ivo Čala.

SADRŽAJ

PREDGOVOR.....	IX
SAŽETAK RADA	XI
SUMMARY	XII
KLJUČNE RIJEČI.....	XIII
POPIS OZNAKA	XIV
POPIS SLIKA	XV
POPIS TABLICA.....	XVI
POPIS GRAFOVA.....	XVI
1. UVOD	1
1.1. HIPOTEZA	2
1.2. PRISTUPI GOSPODARENJU TEHNIČKIM SUSTAVIMA.....	2
1.3. POSLOVNA INTELIGENCIJA.....	2
1.4. ISTRAŽIVANJE O PERCEPCIJI FUNKCIJE ODRŽAVANJA OD STRANE VIŠEG MENADŽMENTA.....	4
1.5. MODEL GOSPODARENJA KORIŠTENJEM POSLOVNE INTELIGENCIJE.....	4
1.6. TESTIRANJE MODELA I HIPOTEZE KROZ STUDIJE SLUČAJA.....	4
2. PRISTUPI GOSPODARENJU TEHNIČKIM SUSTAVIMA.....	5
2.1. DEFINICIJE	5
2.1.1. Definicija materijalne imovine.....	5
2.1.2. Definicija gospodarenja tehničkim sustavima.....	6
2.2. GOSPODARENJE TEHNIČKIM SUSTAVIMA U LANCU STVARANJA VRIJEDNOSTI	6
2.2.1. Uloga gospodarenja tehničkim sustavima u proizvodnom procesu	8
2.3. KAKO JE DOŠLO DO NASTANKA GOSPODARENJA TEHNIČKIM SUSTAVIMA	8
2.3.1. Zadržavanje troškova na istom nivou.....	9
2.3.2. Snižavanje troškova.....	9
2.4. RAZLOZI ZA UVOĐENJE SUSTAVA GOSPODARENJA TEHNIČKIM SUSTAVIMA I OSTALOM MATERIJALNOM IMOVINOM.....	10
2.4.1. Strateški razlozi za fokusiranje na gospodarenje tehničkim sustavima.....	11
2.4.2. Prepoznavanje povoljnih prilika za povećanje produktivnosti imovine	11
2.5. CILJEVI GOSPODARENJA TEHNIČKIM SUSTAVIMA.....	13
2.5.1. Pokazatelji za mjerenje uspješnosti gospodarenja tehničkim sustavima.....	14
2.6. PROCES GOSPODARENJA TEHNIČKIM SUSTAVIMA	23
2.6.1. Gospodarenje kroz profitne centre.....	25
2.7. INFORMACIJSKI SUSTAVI GOSPODARENJA TEHNIČKIM SUSTAVIMA	25

2.8.	ODRŽAVANJE.....	26
2.8.1.	Misija održavanja.....	27
2.8.2.	Razvijanje strategije održavanja.....	28
2.8.3.	Vrste održavanja	30
2.9.	ALATI I METODOLOGIJE KORIŠTENI U GOSPODARENJU TEHNIČKIM SUSTAVIMA	32
2.9.1.	Sustav uravnoteženih ciljeva-BSC.....	32
2.9.2.	Šest Sigma-6σ.....	41
2.10.	PRISTUPI GOSPODARENJA TEHNIČKIM SUSTAVIMA-ZAKLJUČAK.....	43
3.	POSLOVNA INTELIGENCIJA	44
3.1.	NASTANAK DISCIPLINE POSLOVNE INTELIGENCIJE	45
3.1.1.	Činjenice nasuprot mišljenjima.....	47
3.1.2.	Kvaliteta informacija	47
3.1.3.	Smislenost oblika informacija	47
3.1.4.	Kvantiteta informacija.....	48
3.1.5.	Dijeljenje informacija	48
3.2.	INFORMACIJSKI SUSTAVI KAO PODRŠKA BI.....	48
3.2.1.	Prva faza upravljanja podacima	49
3.2.2.	Druga faza upravljanja podacima	49
3.2.3.	Treća faza upravljanja podacima.....	50
3.3.	SKLADIŠTENJE PODATAKA.....	51
3.3.1.	Definicija.....	51
3.3.2.	Strategija kompanije kao preduvjet za DW.....	51
3.3.3.	Arhitektura DW sustava	53
3.3.4.	Razlike između Operativnih baze podataka i DW-a.....	54
3.3.5.	Faze uvođenja DW-a.....	54
3.3.6.	Pozadinski alati i programi.....	55
3.3.7.	Konceptualni model i korisnički alati	57
3.3.8.	Metapodaci i upravljanje DW-om.....	59
3.4.	DUBINSKE ANALIZE (DATA MINING).....	60
3.4.1.	DM aplikacije.....	60
3.4.2.	Prepreke DM-u.....	61
3.4.3.	Tehnike koje koristi DM	63
3.5.	STROJNO UČENJE I MREŽE POVJERENJA.....	64
3.5.1.	Što je strojno učenje?	64
3.5.2.	Kako se strojno učenje primjenjuje u Data Miningu?.....	64
3.5.3.	Bayesova klasifikacija.....	66
3.5.4.	Bayesove mreže povjerenja	69
3.5.5.	Učenje Bayesove mreže povjerenja.....	72
3.6.	POSLOVNA INTELIGENCIJA-ZAKLJUČAK.....	74

4.	ISTRAŽIVANJE O PERCEPCIJI FUNKCIJE ODRŽAVANJA	75
4.1.	SADRŽAJ ISTRAŽIVANJA.....	75
4.1.1.	<i>Ispitanici.....</i>	75
4.2.	REZULTATI ISTRAŽIVANJA	75
4.3.	METODA ANALIZE	78
4.3.1.	<i>Hijerarhijska klaster analiza.....</i>	79
4.3.2.	<i>Interpretacija rezultata hijerarhijske klaster analize.....</i>	79
4.3.3.	<i>Interpretacija rezultata nehijerarhijske klaster analize</i>	79
4.4.	ZAKLJUČAK ISTRAŽIVANJA	80
5.	MODEL GOSPODARENJA KORIŠTENJEM POSLOVNE INTELIGENCIJE	83
5.1.	INTERESI I CILJEVI POJEDINIH DIJELOVA TVRTKE	83
5.2.	UVJETI KOJI MORAJU BITI OSTVARENI ZA OPTIMALAN REZULTAT CIJELE TVRTKE.....	85
5.2.1.	<i>Razgraničenja između strateškog, taktičkog i operativnog nivoa</i>	86
5.3.	MODEL DONOŠENJA ODLUKA.....	88
5.3.1.	<i>Osnovni uvjet modela.....</i>	88
5.3.2.	<i>Definiranje funkcije utjecaja.....</i>	88
5.3.3.	<i>Kriterij prihvatljivosti modela.....</i>	93
5.3.4.	<i>Uloga poslovne inteligencije u određivanju pojedinih vrijednosti funkcije utjecaja.....</i>	93
6.	TESTIRANJE MODELA	95
6.1.	OPIS OBRAĐIVANOGA PROBLEMA	95
6.1.1.	<i>Situacija u tvrtki</i>	95
6.1.2.	<i>Situacija na lokaciji C.....</i>	95
6.1.3.	<i>Situacija sa linijom X.....</i>	96
6.2.	RJEŠENJE NA TEMELJU TEHNIČKIH INFORMACIJA-STUDIJA SLUČAJA	96
6.2.1.	<i>Raspoloživi podaci</i>	96
6.2.2.	<i>Aktivnosti poduzete prije donošenja odluke</i>	97
6.2.3.	<i>Donošenje odluke</i>	98
6.2.4.	<i>Komentar i zaključak.....</i>	98
6.3.	ODLUKA DONESENA KORIŠTENJEM MODELA UZ PRIMJENU POSLOVNE INTELIGENCIJE	98
6.3.1.	<i>Uvodni komentar.....</i>	98
6.3.2.	<i>Raspoloživi podaci</i>	98
6.3.3.	<i>Postupak donošenja odluke.....</i>	99
6.3.4.	<i>Vrijednost funkcije utjecaja.....</i>	101
6.4.	USPOREDBA REZULTATA VARIJANTI STUDIJE SLUČAJA	101
6.4.1.	<i>Pronađeno alternativno rješenje</i>	101
6.5.	TESTIRANJE HIPOTEZE STUDIJOM SLUČAJA	102
6.6.	KRITIČKI OSVRT NA HIPOTEZU I TESTIRANJE HIPOTEZE	102
6.6.1.	<i>Koje se koristi mogu izvući iz ovoga rada?.....</i>	103

7. ZAKLJUČAK.....	105
8. KORIŠTENA LITERATURA.....	108
ŽIVOTOPIS.....	110

PREDGOVOR

Tijekom svoje profesionalne karijere imao sam veliku sreću raditi više raznolikih poslova od kojih je svaki širio moje vidike. Moje prvo radno mjesto bilo je na Fakultetu strojarstva i brodogradnje, gdje sam asistirao u kolegijima "Održavanje" i "Vođenje proizvodnje". Nakon toga slijedi jedno izuzetno intenzivno operativno razdoblje u Pliva-"Održavanje i energetika". Tijekom četiri godine u održavanju, pored svakodnevnih aktivnosti bio sam u mogućnosti pratiti, educirati se i na kraju primjenjivati suvremene koncepte održavanja. Tijekom rada u održavanju bilo je situacija kada mi neke odluke koje sam morao provoditi nisu bile logične. Shvatio sam da je jedan od razloga moje nepoznavanje strategije, poslovne politike kao i nekih osnovnih zakonitosti poslovanja. Želja da savladam i taj izazov ispunila mi se kada sam prešao u "Korporativnu strategiju". Mnoge stvari koje su mi prije bile nejasne i nelogične uvidom u cjelokupnu situaciju u kompaniji pa i u okruženju postale su mi jasne i logične. Mojim prelaskom u jedinicu "Strategija proizvodnje i gospodarenje imovinom" našao sam se u idealnoj situaciji korištenja svojim spoznaja iz operative, kao i helikopterskog pogleda na kompaniju i okruženje koje sam stekao u korporativnoj strategiji. Osim konkretnih informacija i znanja koje sam imao, izuzetno korisno bilo je to što sam znao tko ima određene informacije ili gdje se one mogu naći. Tijekom suradnje sa kolegama iz "Održavanja" i "Proizvodnje" shvatio sam da oni još uvijek imaju isti problem koji sam imao i ja dok sam radio u tom dijelu kompanije. Postoje mnogi načini na koje je moguće riješiti ovaj problem. Od organizacijskih promjena, upravljanja znanjem¹, bolje koordinacije, implementacije raznoraznih aplikacija. Za vrijeme moga rada u Korporativnoj strategiji bavio sam se između ostalog i poslovnom inteligencijom. Uspješno provedena implementacija jednog sustava poslovne inteligencije riješila bi dio problema nedostupnosti potrebnih informacija. Tako sam došao na ideju ispitati eventualnu razliku između odluka o gospodarenju opremom donesenih temeljem informacija nastalih tijekom aktivnosti proizvodnje i održavanja i odluka donesenih temeljem dodatnih informacija o strategiji, dugoročnim planovima prodaje, situaciji u okruženju.

¹ eng. Knowledge Management

Kako se gospodarenje tehničkim sustavima uglavnom odvija kroz aktivnosti održavanja, moja ideja naišla je na protupitanja:

"Kakve veze ima održavanje i poslovna inteligencija?" Neosporna je činjenica da ta veza još nije uspostavljena. Zašto u održavanju ne koristiti poslovnu inteligenciju ako pomoću nje možemo donijeti odluku koja će rezultirati financijskom koristi za tvrtku? Normalno nećemo uvoditi poslovnu inteligenciju u kompaniju radi gospodarenja tehničkim sustavima! Namjera mi je ispitati utjecaj poslovne inteligencije na donošenje odluka, usporediti akcije i rezultate sa onima donesenim samo na temelju "tehničko-taktičkih" informacija.

SAŽETAK RADA

Proteklih trideset godina gospodarenje tehničkim sustavima razvijalo se od zadržavanja troškova na istom nivou, preko snižavanja troškova do modela koji danas poznajemo. Gospodarenje tehničkim sustavima ključno je za proizvodnju i procese u tvrtkama gdje su optimalna raspoloživost, pouzdanost i troškovna učinkovitost preduvjeti za profitabilno poslovanje. U gospodarenju tehničkim sustavima izuzetno je bitno donošenje odluka na temelju najboljih raspoloživih informacija.

Proteklih par godina znatno je porastao broj implementacija sustava poslovne inteligencije. U mnogim slučajevima očekivani rezultati implementacija nisu ostvareni. Jedan od glavnih razloga je parcijalni pristup poslovnoj inteligenciji, koji je često baziran na zahtjevima jedne funkcije (najčešće financija). U takvim situacijama gospodarenje tehničkim sustavima nije uključeno u implementaciju.

U Hrvatskoj se u velikim proizvodnim tvrtkama ulogom gospodarenja tehničkim sustavima najčešće bavi funkcija održavanja. Istraživanje o percepciji funkcije održavanja pokazalo je da održavanje nije dovoljno povezano sa strategijom, te da postojeći sustav izvještavanja nije na zadovoljavajućem nivou.

U svrhu boljeg donošenja odluka kreiran je model donošenja odluka, čiji je bitan čimbenik poslovna inteligencija. Studija slučaja pokazala je da se odluka donesena upotrebom poslovne inteligencije razlikuje od odluke donesene samo temeljem tehničkih informacija. Time je potvrđena pretpostavka da poslovna inteligencija može doprinijeti efikasnijem gospodarenju tehničkim sustavima.

SUMMARY

During last thirty years Physical Asset Management evolved from practices of keeping cost at the same level, through cost cutting practices to current model. Physical Asset Management is essential for production and processes in companies where optimal Availability, Reliability and cost effectiveness are prerequisites for profit. Very important factor in Physical Asset Management is decision making based on best available information. The number of Business Intelligence Systems Implementation increased rapidly in last few years. Expected results were not achieved in the vast number of implementation. One of the main reasons for that is partial approach to Business Intelligence, often based on one function (often Finance) requirements. Usually, Physical Asset Management is not included in implementation. The most common situation in Croatia is that maintenance function plays main role in Physical Asset Management. The maintenance function perception survey indicated that maintenance is not linked enough with strategy and that reporting system is unsatisfactory.

To improve decision making process and information availability, decision making model is created. Business Intelligence is important contributor to the model. Case studies showed that a decision based on model with included Business Intelligence differs from decision based on technical information. That is confirmation of assumption that business intelligence could contribute to more effective Physical Asset Management.

KLJUČNE RIJEČI

Gospodarenje tehničkim sustavima	Technical systems management
Gospodarenje materijalnom imovinom	Physical Asset Management
Poslovna inteligencija	Business Intelligence
Skladište podataka	Data Warehouse
Bayesova mreža povjerenja	Bayesian belief network
Model donošenja odluka	Decision making model

POPIS OZNAKA

Oznaka	Naziv (eng)	Naziv
RONA	Return On Net Assets	Povrat na neto uložena sredstva
ROCE	Return On Capital Employed	Povrat angažiranog kapitala
LCP	Life Cycle Profit	Profit životnog vijeka opreme
LCC	Life Cycle Cost	Troškovi životnog vijeka opreme
EVA	Economic Value Added	Dodana ekonomska vrijednost
OT	Operational Time	Ukupno raspoređeno proizvodno vrijeme
RT	Repair Time	Vrijeme popravka
WT	Waiting Time	Vrijeme tijekom kojega se čeka
A	Availability	Raspoloživost
MTBF	Mean Time Between Failures	Srednje vrijeme između kvarova
MODT	Mean Operating Delay Time	Srednje operativno vrijeme zastoja
MLDT	Mean Logistic Delay Time	Srednje logističko kašnjenje
MTTR	Mean Time To Repair	Srednje vrijeme popravka
MPDT	Mean Preventive maintenance Delay Time	Srednje vrijeme zastoja zbog preventivnog održavanja
MIT	Mean Idle Time	Srednje vrijeme čekanja na operacije
MOT	Mean Operational Time	Srednje operativno vrijeme
MWT	Mean Waiting Time	Srednje vrijeme čekanja
MTTM	Mean Time To Maintain	Srednje vrijeme održavanja
MTTF	Mean Time To Failure	Srednje vrijeme do kvara
MDT	Mean Delay Time	Srednje vrijeme zastoja
MUT	Mean Up Time	Srednje vrijeme ispravnosti
MRMT		Srednje vrijeme održavanja u radu
ROI	Return On Investment	Povrat na investiciju
NPV	Net Present value	Neto sadašnja vrijednost
OEE	Overall Equipment Effectiveness	Cjelovita učinkovitost opreme

POPIS SLIKA

Red. br.	Naziv	Stranica
	Slika 1:Metodologija izrade magistarskog rada	3
	Slika 2:Gospodarenje tehničkim sustavima u proizvodnom procesu [4]	8
	Slika 3:Evolucijom do gospodarenja tehničkim sustavima [4].....	8
	Slika 4:Usmjerenost gospodarenja tehničkim sustavima prema rezultatima	13
	Slika 5:Srednja vremena.....	15
	Slika 6: Prikaz troškova životnog ciklusa materijalne imovine iz perspektive korisnika	18
	Slika 7: povezivanje tehničkih shvaćanja i elemenata troškova tijekom životnog vijeka	20
	Slika 8:Pojednostavnjena struktura informacijskog sustava gospodarenja imovinom	26
	Slika 9:Usklađenost procesa održavanja sa gospodarenjem tehničkim sustavima [4]	30
	Slika 10: Razvoj pristupa i koncepcija održavanja [14]	31
	Slika 11:Principi strateški vođene organizacije	34
	Slika 12:Arhitektura BSC-a	35
	Slika 13:Komponente BSC-a	36
	Slika 14:Primjer strukture strateške mape	37
	Slika 15: Strategija kao kontinuirani proces	39
	Slika 16: Infrastruktura BI sustava	46
	Slika 17:Dodirne točke funkcijskih aplikacija i BI	49
	Slika 18:Tri faze upravljanja podacima [26]	50
	Slika 19:Arhitektura DW sustava	53
	Slika 20: Prikaz modela višedimenzionalnih podataka	57
	Slika 21:Primjer: Jednostavna Bayesova mreža povjerenja	71
	Slika 22: Rezulati klaster analize prikazani u dendrogramu	80
	Slika 23:Nivoi menadžmenta	86

POPIS TABLICA

Red. br.	Naziv	Stranica
	Tablica 1: Pojašnjenja vremenskih definicija	16
	Tablica 2: Popis pojmova korištenih u sustavu poslovne inteligencije	45
	Tablica 3: Tablica uvjetovanih vjerojatnosti (CPT)	71
	Tablica 4: Anketni list	77
	Tablica 5: Rezultati istraživanja	78
	Tablica 6: <i>Ključni pokazatelji poslovanja grupe Podravka za 2004. godinu</i>	84
	Tablica 7: Strateški horizonti raznih industrija	87

POPIS GRAFOVA

Red. br.	Naziv	Stranica
	Graf 1: Važnost poznavanja utjecaja troškova životnog ciklusa na faze životnog ciklusa	19
	Graf 2: LCC u odnosu na razine dizajna [10]	21
	Graf 3: Trendovi troškova životnog ciklusa kroz životni vijek fizičkih sredstava [11] ..	23

1. UVOD

U današnje vrijeme svjedoci smo sve oštrije tržišne utakmice. Zadržati konkurentnu cijenu, a istovremeno imati solidan profit moguće je jedino uz smanjenje troškova poslovanja. Tako se pred menadžera ili inženjera zaduženoga za održavanje više ne postavlja samo zahtjev za raspoloživošću proizvodne opreme i tehničkih sustava, koji će on uspješno ispuniti koristeći se svojim tehničkim znanjima i podacima koje je sustavno prikupljao i obrađivao. Zahtjev koji se postavlja je, pronaći optimalan način gospodarenja proizvodnim sredstvima to jest tehničkim sustavima, takav koji će podržati proizvodni proces dostatnim kapacitetima, uz minimalne ukupne troškove.

Da bi se ispunio taj zahtjev, pored inženjerskog pogleda na problem, potrebno je u donošenje odluke uključiti i širi aspekt internog i eksternog poslovnog okruženja, te postići usklađenost sa strategijom tvrtke. Potrebno je sa taktičkog nivoa izdići se na strateški. Strategija je dugoročna, a bilo kakva strateška odluka zahtjeva detaljnu analizu cjelokupnoga okruženja.

Postavlja se pitanje jesu li problemi gospodarenja tehničkim sustavima uključeni u strateška pitanja?

Odgovor na to proizlazi iz slijedeće činjenice: U industrijskoj ekonomiji kompanije su stvarale vrijednost pretvaranjem sirovina u gotove proizvode korištenjem osnovnih sredstava. Studija koju je 1982 proveo "*Brokings Institute*" [1] pokazala je da knjigovodstvena vrijednost materijalne imovine čini 62% tržišne vrijednosti kompanije. Deset godina kasnije taj udio pao je na 38%. Najnovija istraživanja došla su do spoznaja da je ta vrijednost pala na svega 10-15% tržišne vrijednosti kompanije. Zbog te činjenice teško je za očekivati da će prilikom donošenja strateških odluka problemi gospodarenja tehničkim sustavima biti presudni!

Što je moguće realno postići? Funkcija gospodarenja tehničkim sustavima mora prilikom donošenja odluka biti upoznata sa svim relevantnim informacijama unutar kompanije kao i u okruženju.

Problem je naizgled jednostavan. Potrebno je donositi odluke na temelju svih informacija i znanja koja postoje u kompaniji, a ne samo onih standardno raspoloživih u funkciji gospodarenja tehničkim sustavima. Poslovna inteligencija primjenjuje se za rješavanje takvih problema, ali do sada nije primjenjivana u funkciji gospodarenja tehničkim sustavima odnosno materijalnom imovinom općenito.

Zašto poslovna inteligencija? Prema [2] U EU 82% tvrtki sa prihodom >10m\$ ima sustav poslovne inteligencije. Taj podatak govori o nužnosti implementacije i korištenja jednoga takvog sustava.

Isto tako sve iznesene pretpostavke i istraživanja u ovom radu odnositi će se na tvrtke koje imaju prihode veće od 20m\$ i vlastitu proizvodnju (veće proizvodne tvrtke).

U ovom radu namjera mi je uključivanjem poslovne inteligencije definirati pristup gospodarenja tehničkim sustavima koji će biti optimalan na nivou cjelokupne organizacije, a ne parcijalno optimalan na nivou pojedinih organizacijskih jedinica.

Metodologija izrade rada prikazana je na Slika 1, "Metodologija izrade magistarskog rada".

1.1. Hipoteza

Preduvjet za efikasnije gospodarenje tehničkim sustavima u većim proizvodnim tvrtkama je donošenje odluka na temelju svih informacija, a ne samo onih dostupnih u funkciji održavanja, odnosno gospodarenja tehničkim sustavima. Poznavanje strategije tvrtke, dugoročnih planova prodaje, planova uvođenja novih proizvoda, međusobno poznavanje resursa i sposobnosti dislociranih proizvodnih lokacija, poznavanje trendova u poslovnom okruženju, te trendova na tržištu neophodne su informacije kod donošenja odluka.

Sve te informacije sakuplja i obrađuje sustav poslovne inteligencije. Primjenom sustava poslovne inteligencije u gospodarenju materijalnom imovinom, a posebno tehničkim sustavima moguće je donositi kvalitetnije odluke koje će rezultirati racionalnijim gospodarenjem i boljim iskorištenjem resursa tvrtke.

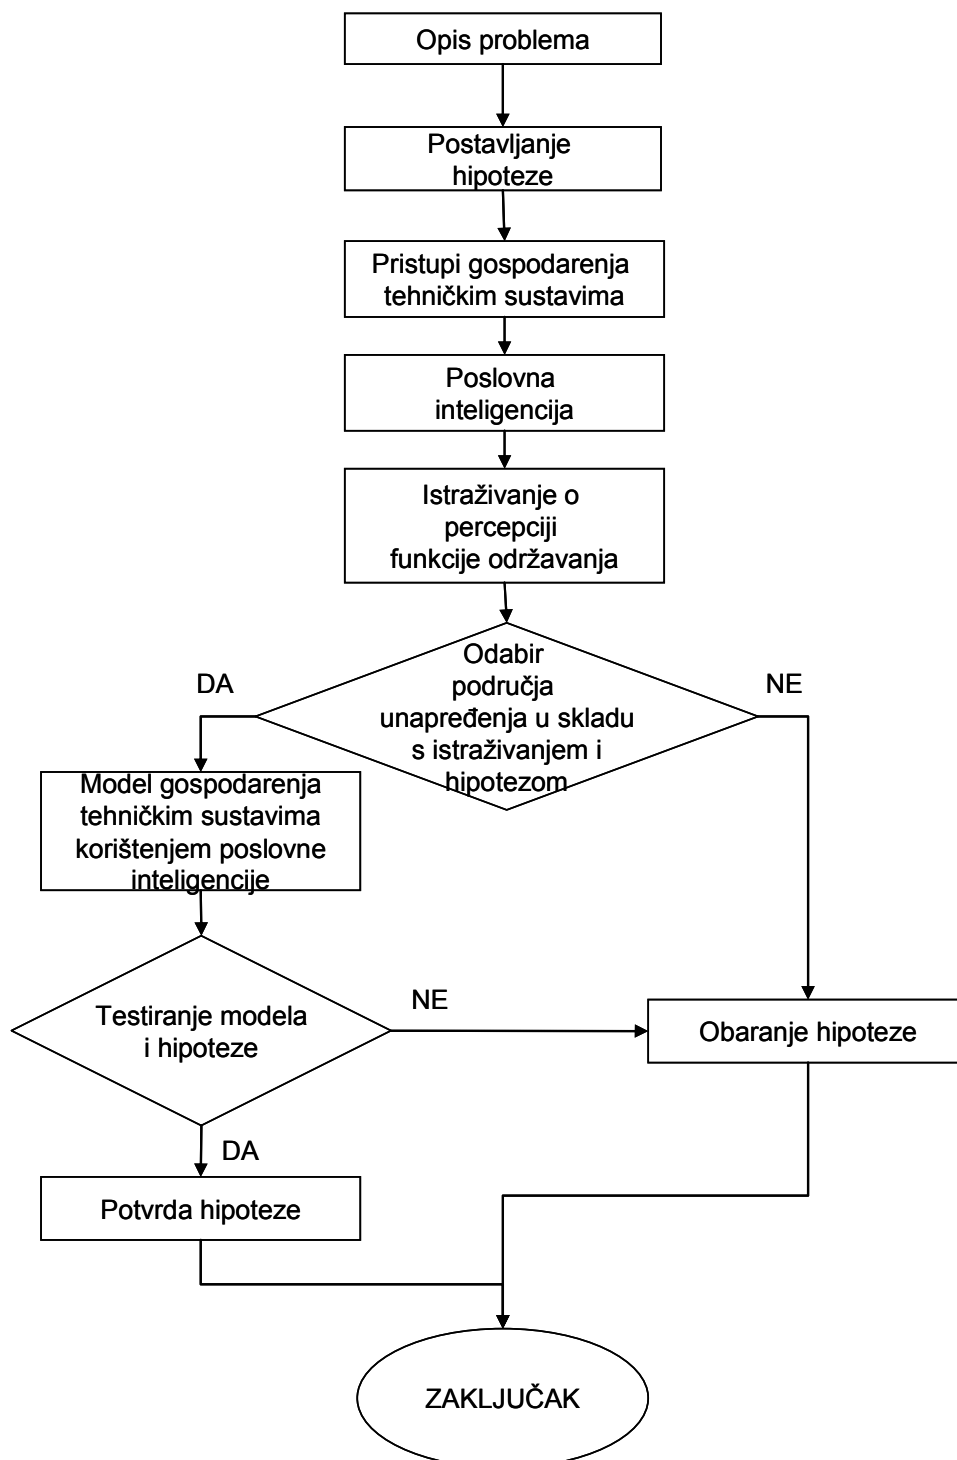
1.2. Pristupi gospodarenju tehničkim sustavima

S obzirom na postavljenu hipotezu, neophodno je proučiti trendove i pristupe u gospodarenju tehničkim sustavima. Potrebno je istražiti koji su se pristupi razvili u posljednje vrijeme, i na koji način sustavan pristup gospodarenju tehničkim sustavima može doprinijeti uspjehu tvrtke.

1.3. Poslovna inteligencija

Kako bi uopće mogli razrađivati uvođenje sustava poslovne inteligencije u gospodarenje tehničkim sustavima, to jest gospodarenje tehničkim sustavima,

potrebno je dati pregled i strukturu današnjeg sustava poslovne inteligencije uključivši i aspekt informacijskih tehnologija (korišteni alati i mogućnosti koje oni pružaju).



Slika 1: Metodologija izrade magistarskog rada

1.4. Istraživanje o percepciji funkcije održavanja od strane višeg menadžmenta

U pristupu gospodarenju tehničkim sustavima najznačajniji dio zauzimaju pristupi održavanja. Kako u hrvatskoj još nije u toj mjeri zaživio cjeloviti pristup, ovo istraživanje bazirano je na aktivnostima funkcije održavanja. Svrha ovoga istraživanja je ustanoviti u kakva je percepcija funkcije održavanja od strane višeg menadžmenta, a posebno treba izvući u kojoj mjeri održavatelji imaju utjecaja na strategiju i jeli viši menadžment upoznat sa problemima održavanja, i u kojoj mjeri daje podršku rješavanju tih problema. Ukoliko rezultati ovoga istraživanja pokažu da postoje područja koja je moguće značajno unaprijediti primjenom sustava poslovne inteligencije, tada je moguće pristupiti izradi modela. U suprotnom nije moguće kreirati model i hipoteza se obara.

1.5. Model gospodarenja korištenjem poslovne inteligencije

Da bi od hipoteze mogli imati koristi potrebno je definirati model koji će omogućiti korištenje znanja dobivenih kroz primjenu poslovne inteligencije kod donošenja odluka u gospodarenju tehničkim sustavima.

1.6. Testiranje modela i hipoteze kroz studije slučaja

Model je potrebno testirati da bi ustanovili doprinosi li on donošenju racionalnijih odluka. Kako je riječ o kompleksnim modelima i odlukama, odabran je pristup testiranja kroz studiju slučaja. Usporediti će se odluka donesena u bliskoj prošlosti sa odlukom donesenom primjenom modela donošenja odluka uz korištenje sustava poslovne inteligencije.

2. PRISTUPI GOSPODARENJU TEHNIČKIM SUSTAVIMA

Cilj ovoga rada je pronaći najučinkovitiji model gospodarenja tehničkim sustavima. U pristup gospodarenja tehničkim sustavima već su uključeni značajniji koncepti održavanja i razni drugi pristupi i to je razlog zašto ga uzimam kao jedan od temeljnih dijelova ovoga rada.

2.1. Definicije

Na samom početku istraživanja potrebno je pojasniti pojmove i definicije koji se koriste u engleskom i hrvatskom jeziku, kako bi se izbjegle terminološke nejasnoće.

2.1.1. Definicija materijalne imovine

Naziv materijalna imovina je prijevod pojma "Physical Asset". Prema [3] u hrvatskoj je odgovarajući pojam "Dugotrajna materijalna imovina". To je imovina poduzeća koja se javlja u materijalnom (fizičkom obliku). Riječ je o zemljištu, poslovnim zgradama, opremi, transportnim sredstvima koje poduzetnik koristi u obavljanju svoje registrirane djelatnosti.

S računovodstvenoga motrišta dugotrajna materijalna imovina dijeli se na:

1. Nekretnine
2. **Postrojenja i opremu**
3. Ostalu dugotrajnu materijalnu imovinu

Ovo pojašnjenje bilo je nužno da se precizno definira na čemu će biti fokus ovoga rada. U nastavku rada prilikom analiza, kada će biti upotrijebljen pojam "tehnički sustav" podrazumijevati će se "Postrojenja i oprema", iako bi se ove zakonitosti mogle primijeniti na sve vrste materijalne imovine kao što to sugerira engleski naziv "Physical Asset Management".

Pod postrojenja i opremu spadaju: kotlovnice, strojarnice, elektronička oprema, telefonske centrale, strojevi koji služe za proizvodnju, uredska oprema, pogonski uredski inventar, krupan alat koji služi za proizvodnju, transportna sredstva, osobni automobili, autobusi, teretna vozila itd.

2.1.2. Definicija gospodarenja tehničkim sustavima

Prema J. S. Mitchell-u [4] definicija gospodarenja tehničkim sustavima glasi:

"Gospodarenje tehničkim sustavima je strateški, potpuno integrirani, sveobuhvatni proces i kultura usmjerena prema postizanju najvećeg iskorištenja, operativne učinkovitosti^{II} i stvorene vrijednosti za vrijeme životnog vijeka proizvodne opreme i ostalih sustava".

Ciljeve postavljene u definiciji gospodarenje tehničkim sustavima ostvaruje na slijedeći način:

"Optimizira operativnu učinkovitost procesa i sredstava za proizvodnju sa svrhom postizanja maksimalnog životnog vijeka i povrata uložених sredstava. Omogućuje sustavno postavljanje prioriteta i implementaciju procesa, pristupa i tehničkih poboljšanja, kako bi se ispunili zahtjevi sigurnosti, raspoloživosti i kvalitete, a da su troškovi u najmanju ruku održivi s obzirom na operativne, tržišne i poslovne uvjete.

2.2. Gospodarenje tehničkim sustavima u lancu stvaranja vrijednosti^{III}

Uloga svih organiziranih formi ljudskoga poduzetništva mogla bi se ukratko opisati na slijedeći način: uzmemo ulazni objekt, dodamo mu vrijednost i tako on postaje izlazni objekt. U proizvodnji ulazni objekti su sirovine kojima se dodaje vrijednost pretvarajući ih u nešto drugo, što se na kraju prodaje kupcima. Ista logika vrijedi i za uslužne djelatnosti, na primjer kod bolnica u proces ulazi bolestan pacijent, kojemu se dodaje vrijednost izlječenjem njegove bolesti, da bi očekivani izlaz bio zdraviji pacijent.

Gotovo svi lanci vrijednosti, naročiti oni profitni sastoje se od tri glavna organizacijska elementa. Na ulazu se nalazi nabava koja pronalazi sirovine, zatim imamo operacije koje su odgovorne za izvođenje procesa dodavanja vrijednosti, da bi se na kraju lanca nalazili marketing i prodaja koji moraju pronaći potencijalne kupce i uvjeriti ih da kupe taj proizvod.

^{II} eng. Operating Effectiveness

^{III} eng. Value Chain

Te tri glavne organizacijske funkcije dopunjene su glavnim funkcijama podrške, zaduženim za gospodarenje imovinom. Svi lanci vrijednosti imaju tri vrste imovine: financijska imovina, ljudska imovina ili ljudski resursi i materijalna imovina. Da bi se proces dodavanja vrijednosti odvijao efikasno i učinkovito neophodno je upravljati na odgovarajući način sa sve tri kategorije.

Gospodarenje financijskom imovinom

Odjel financija ne odlučuje što će se kupiti ili prodati (osim sredstva koja koriste za vlastitu uporabu). Takve odluke donose ljudi koji su odgovorni za pojedine dijelove lanca opskrbe. Odjel financija jednostavno osigurava financijska sredstva potrebna kako bi se proces dodavanja vrijednosti mogao nesmetano odvijati u skladu sa misijom tvrtke.

Odjel financija je funkcija podrške. Određuje politike i procedure vezano za financije, koje moraju pratiti osobe iz lanca vrijednosti. Važna uloga financija je praćenje ostvarenih financijskih rezultata. Odjel financija usprkos relativno malom broju ljudi koji mu pripadaju ima neizmjereno važnu ulogu, a direktor financija obično je i član uprave.

Gospodarenje ljudskim resursima

Kadrovski poslovi ne određuju zaposlenicima njihove dnevne aktivnosti (osim u svojem odjelu). Time se bavi menadžment u različitim dijelovima lanca vrijednosti. Kadrovski poslovi osiguravaju da organizacija ima ljude potrebne da bi se obavio proces dodavanja vrijednosti u skladu sa misijom tvrtke.

Kadrovski poslovi su funkcija podrške. Određuje politike i procedure vezano uz kadrove, koje moraju pratiti osobe iz lanca vrijednosti. Također pomažu kod akvizicije novih kadrova. Služba kadrovskih poslova je izuzetno moćna u organizaciji, a direktor kadrovske službe obično je visoko pozicioniran u hijerarhiji.


Gospodarenje tehničkim sustavima

Zadaci koje obavlja su čista funkcija podrške. Uključeni su u postavljanje procedura za gospodarenje tehničkim sustavima koje moraju poštivati svi iz lanca stvaranja vrijednosti. Zaduženi su za nabavu novih tehničkih sustava kada je to potrebno. Ako usporedimo sličnosti sa financijama i kadrovskima mogli bi povući paralelu i zaključiti kako se kod financija i kadrovskih radi o maloj grupi ljudi, ali utjecajnoj u

organizaciji. Funkcija gospodarenja tehničkim sustavima je mnogo veća od ostale dvije, difuznija, slabije fokusirana i niti otprilike toliko utjecajna kao prethodne dvije. Sve navedeno znači da nije niti toliko efikasna [4]. Jedan od glavnih razloga takvog stanja je prema [5] opterećenost zaposlenika svakodnevnim poslovima koji su uglavnom hitni i visokog prioriteta.

2.2.1. Uloga gospodarenja tehničkim sustavima u proizvodnom procesu

Gospodarenje tehničkim sustavima u proizvodnom procesu ima ulogu osiguravanja predvidivog kapaciteta (vidi Slika 2)




Slika 2: Gospodarenje tehničkim sustavima u proizvodnom procesu [4]

Predvidivi kapacitet uvjetuje da proizvodna oprema radi sa optimalnom učinkovitošću i pouzdanošću, kako bi kapaciteti bili raspoloživi u skladu sa potrebama i kako bi se ostvarili rokovi, kvaliteta i troškovi.

2.3. Kako je došlo do nastanka gospodarenja tehničkim sustavima

Gospodarenje tehničkim sustavima nastalo je evolucijom pristupa gospodarenja koja traje već tridesetak godina. Faze su prikazane na Slika 3.



Slika 3: Evolucijom do gospodarenja tehničkim sustavima [4]

2.3.1. Zadržavanje troškova na istom nivou

Do sredine 1970' opremom se upravljalo uglavnom reaktivnim "zadržavanjem troškova na istom nivou"^{IV}. Većina industrija imala je takve profite koji su bili više nego dovoljni za pokrivanje više malih grešaka, kao i za povremene velike greške. Zaposlenici održavanja nisu bili u većoj mjeri povezani sa budžetom i njihova primarna odgovornost bila je otklanjanje kvarova što je brže moguće. Budžeti za održavanje opreme bili su bazirani uglavnom na prošlogodišnjima. Postojala je izuzetno slabo razvijena svijest i motivacija o potrebi za promjenama.

Najbolji primjer za to je američka automobilska industrija. Do ranih 1970' američki proizvođači automobila nisu previše marili za kvarove na proizvodnoj opremi, jer sva njihova konkurencija je koristila radnu snagu sa sličnim radnim ugovorima, jednake proizvodne procese i opremu, jednaku operativnu učinkovitost i bila suočena sa otprilike istim brojem zastoja. U takvom okruženju kupac je snosio troškove neučinkovitosti. Onda su se na američkom tržištu pojavili japanci sa boljim proizvodima, koji su uz to proizvedeni uz niže troškove.

2.3.2. Snižavanje troškova

Da bi postali konkurentni, američki proizvođači bili su prisiljeni na povećanje kvalitete uz istovremeno snižavanje proizvodnih troškova i skraćivanje proizvodnog ciklusa. Sve se moralo promijeniti.

Inicijalni fokus bio je na povećanju kvalitete i snižavanju troškova^V. Tako su razni reinženjeringi i optimizacije ustvari bili eufemizmi za snižavanje troškova i smanjivanje broja zaposlenih. Korporacije su se počele uspoređivati sa konkurencijom kako bi ustanovili kakve su ustvari njihove relativne performanse na sve zahtjevnijem tržištu. Na području održavanja mnogi su bili iznenađeni kada su otkrili da razlika između njih i najboljih u industriji iznosi i do 30%. To je bio poziv za buđenje. U nekim slučajevima prepoznato je da su mnoga smanjenja troškova kratkoročna i da ih je nemoguće održavati. Postoje mnoge anegdote o menadžerima koji su vrlo brzopleto snizili troškove smanjivanjem broja zaposlenih, ukidanjem određenih programa, i odgađanjem zahvata održavanja ispod nivoa održivosti. Neko vrijeme takav pogon je preživio nošen inercijom prethodnih praksi, štoviše uspio je ostvariti povećani profit. Menadžeri koji su proveli takve promjene obično su

^{IV} eng. Cost Containment

^V eng. Cost Reduction

promovirani prije pojave problema. Njihovi nasljednici morali su se nositi sa problemima koji su bili direktna posljedica zanemarivanja njihovih prethodnika. Novi menadžeri okrivljeni su za nastale probleme, tako da su njihovi prethodnici izgledali još vredniji i sposobniji.

Vodeći izvršni direktori shvatili su da poslovanje proizvodnih pogona mora generirati profit koji je veći od troška kapitala uvećanog za odgovarajuću premiju povezanu sa rizikom poslovanja. U to vrijeme na tržištu kapitala bilo je moguće ostvariti 4-6% profita na uloženo, uz nikakav ili minimalan rizik, te zbog toga nije postojao interes za investiranje u proizvodnju, ukoliko profiti nisu iznosili barem nekoliko postotaka više. Mnogi proizvođači bili su šokirani spoznajom da su profiti njihovih proizvodnji manji od troška kapitala. To spoznaja postala je ključni imperativ za kontinuirano poboljšanje operativne učinkovitosti koje je evoluirala do sustava gospodarenja tehničkim sustavima.

2.4. Razlozi za uvođenje sustava gospodarenja tehničkim sustavima i ostalom materijalnom imovinom

Gospodarenje tehničkim sustavima je poslovno orijentirano, fokusirano na profit i usmjereno na postizanje najveće operativne učinkovitosti imovine tijekom životnog ciklusa [6]. Proces započinje projektiranjem, nastavlja se kroz nabavu, instalaciju, rad i održavanje. Omogućuje postavljanje mjera koje povezuju poslovne i financijske ciljeve kako bi se prepoznale povoljne prilike i mjere ostvarenja postavljenih ciljeva. Informacijski sustavi pružaju uvid u trenutni status, predviđaju životni vijek i kapacitete imovine. Zahtjevi operative i logistike ključni su elementi gospodarenja tehničkim sustavima. Održavanje se nalazi u sklopu gospodarenja tehničkim sustavima i smatra se vitalnim dijelom operacija i proizvodnje sa ciljem postizanja operativne učinkovitosti. U sklopu gospodarenja tehničkim sustavima održavanjem se upravlja kao ključnom poslovnom aktivnošću koja može donijeti profit.

2.4.1. Strateški razlozi za fokusiranje na gospodarenje tehničkim sustavima

Obično se pojavljuju četiri ključna strateška razloga zbog kojih bi se neka tvrtka trebala fokusirati na povećanje produktivnosti imovine:

- **Konkurencija postiže značajno bolje rezultate:** Bez obzira o kojoj industriji se radi, ukoliko je produktivnost imovine ispod prosjeka direktnih konkurenata, tvrtka riskira financijsku krizu
- **Tvrtka je iscrpila sve ostale mogućnosti podizanja vrijednosti dionica:** U ovom slučaju usmjerenost na produktivnost imovine ustvari je jedini odgovor jer su ostali načini pružanja povrata dioničarima iscrpljeni
- **Povećana produktivnost imovine neophodna je za provođenje nove strategije:** Mnoge tvrtke su shvatile da ukoliko žele bolje odgovarati na zahtjeve tržišta moraju kombinirati visoko fleksibilnu proizvodnju sa niskim zalihama i poboljšanjem usluga. Stvarni razlog za povećanje produktivnosti imovine je napor da se oslobodi dio kapitala kako bi se mogao financirati rast.
- **Lanac vrijednosti u industriji se rascjepkava:** Pod utjecajem deregulacije, brzorastućeg broja tržišnih mehanizama i nove ekonomije informacija, sve više i više industrija se rascjepkava. U nekim slučajevima visoka produktivnost imovine je daleko važnija strateška poluga od tradicionalnog lanca vrijednosti.

2.4.2. Prepoznavanje povoljnih prilika za povećanje produktivnosti imovine

Četiri su osnovna koraka prema poboljšanju produktivnosti materijalne imovine:

- Poznavanje strukture imovine
- Raščlanjivanje poslovnih aktivnosti u svrhu identifikacije ključnih područja akcija
- Prilagođavanje benchmarkinga vlastitim potrebama
- Procjena učinka operativnih unapređenja na vrijednost dionica

2.4.2.1 Poznavanje strukture imovine

Mnogi menadžeri se još uvijek posvećuju isključivo stanju računa dobiti i gubitka. Pažljivo prate količinu prodaje i profit, ali jako malo pažnje posvećuju sredstvima neophodnim za postizanje tih rezultata. Zbog toga prvi korak je dobro poznavanje

balance stanja. Pored toga neophodno je imati dublji uvid od onoga koji pružaju brojke u bilanci stanja. Mnogi knjigovodstveni propisi čija je svrha nastanka prijava poreza i izvještavanje dioničara, ustvari sakrivaju što se ustvari događa sa poslovanjem. Na primjer, tipičan pokazatelj balance stanja su koeficijenti amortizacije kod izvještavanja o vrijednosti imovine. Ali vrijednost amortizacije ne pokazuje nužno operativnu vrijednost imovine ili stvarne troškove njezine zamjene. Zbog toga je nemoguće učinkovitost imovine jedne tvrtke uspoređivati sa njezinom konkurencijom. Na temelju takvih podloga menadžment može krivo procijeniti dugoročnu operativnu vrijednost imovine te donositi pogrešne odluke vezano uz investicije ili rast. Bolji pristup je "vrijednost zamjenskih sredstava" koja u obzir uzima vrijednost novih sredstava najnovijih tehnologija koje se mogu nabaviti na tržištu.

2.4.2.2 Raščlanjivanje poslovnih aktivnosti u svrhu identifikacije ključnih područja akcija

Izuzetno je bitno identificirati proizvode ili poslovne aktivnosti kod kojih je produktivnost sredstava najvažnija i gdje je moguće ostvariti najveći napredak. Zato je potrebno napraviti odmak od prosjeka kako bi se uvidjele razlike u izvršenju između pojedinih proizvoda, pogona ili cijelih poslovnih jedinica.

2.4.2.3 Prilagođavanje benchmarkinga vlastitim potrebama

Bilo koji smisleni pristup poboljšanju produktivnosti imovine mora uključivati opsežan benchmarking, međutim tvrtke moraju biti sigurne da je njihov benchmarking relevantan za kompetitivnu situaciju u području njihove poslovne aktivnosti. Mnoge tvrtke shvatile su da im je proces benchmarkinga donio puno manje koristi nego što su očekivali, obično zbog pogrešnog pristupa. Nisu odabrali pravi skup tvrtki s kojima su radile usporedbe, niti su odabrale prikladne tvrtke s kojima su uspoređivale pojedine segmente poslovanja, ili nisu shvatili uzroke koji objašnjavaju rezultate.

Da bi izbjegli takav ishod, neophodno je unaprijed obratiti posebnu pažnju, kako bi se osiguralo da su tvrtke s kojima se uspoređuje uistinu usporedive. Ponekad neće biti relevantna usporedba sa nekom tvrtkom, već sa određenim poslovnim područjem ili čak jedinicom konkurentske tvrtke. Ponekad se treba odmaknuti od usporedbe sa tvrtkama iz iste industrije i na taj način istražiti modele poslovanja drugih industrija,


kako bi ih prilagodili i usvojili. Isto tako ponekad interni benchmarking može biti koristan kao i eksterni. Interni benchmarking koji može ukazati na razlike u poslovanju pojedinih jedinica može biti koristan za uvjeravanje nižeg menadžmenta kako su poboljšanja izvediva.

2.4.2.4 Procjena učinka operativnih unapređenja na vrijednost dionica

Jednom kad tvrtka identificira potencijalna mjesta za operativna poboljšanja, treba nastojati procijeniti kakav će utjecaj ta poboljšanja imati na vrijednost koju dobivaju dioničari. Nemoguća su brza predviđanja takvih efekata i zato postoje metodologije za izračunavanje približnog utjecaja povećanja produktivnosti imovine na ukupnu vrijednost koja se vraća dioničarima.

2.5. Ciljevi gospodarenja tehničkim sustavima

Gospodarenje tehničkim sustavima od esencijalne je važnosti za procese i proizvodnju u poduzećima gdje je optimalna raspoloživost, pouzdanost i troškovna učinkovitost životnog vijeka opreme neophodna za profitabilnost u današnjem okruženju. Gospodarenje tehničkim sustavima osigurava da proizvodni kapaciteti udovoljavaju zahtjevima proizvodnih rokova, kvalitete i troškova.



Slika 4: Usmjerenost gospodarenja tehničkim sustavima prema rezultatima

Na Slika 4 vidljivo je da prihodi, iskorištenje opreme i troškovi imaju ključan doprinos na učinkovitost koja se mjeri pomoću RONA (Povrat na neto uložena sredstva)^{VI} i ROCE (povrat angažiranog kapitala)^{VII}

Drugim riječima cilj gospodarenja tehničkim sustavima je povećanje učinkovitosti, financijski pokazatelji kojima ga mjerimo su ROCE, RONA, EVA^{VIII} (dodana ekonomska vrijednost).

Isti ciljevi se mogu mjeriti različitim pokazateljima. Tako je dosta čest slučaj da se mjeri LCP^{IX}. To je pokazatelj koji mjeri profit ostvaren tijekom životnog vijeka proizvoda⁷. Puno se češće koristi LCC^X, pokazatelj koji prati ukupne troškove životnog vijeka opreme. Postoje brojni pokazatelji kojima mjerimo uspješnost gospodarenja tehničkim sustavima, a zbog njihove važnosti potrebno je pobrojati neke od njih i dodatno ih pojasniti.

2.5.1. Pokazatelji za mjerenje uspješnosti gospodarenja tehničkim sustavima

Prva grupa su RAM pokazatelji^{XI} (Pouzdanost, raspoloživost, pogodnost za održavanje) dok u drugu grupu spadaju pokazatelji životnog vijeka imovine (LCC).

2.5.1.1 RAM pokazatelji

Pouzdanost^{XII} je, prema europskoj normi EN 13306^{XIII}, sposobnost elementa da izvodi zahtijevanu funkciju u zadanim uvjetima unutar zadanog vremenskog razdoblja. Valja napomenuti da se pouzdanost također koristi kao mjera pouzdanosti izvedbe, pa se time može definirati kao *vjerojatnost* da će sustav, sredstvo ili komponenta izvoditi propisanu aktivnost u danom vremenu bez kvara, ukoliko se njome ispravno služi. Radi lakšeg razumijevanja, navedimo još i opće prihvaćenu

^{VI} RONA-Return On Net Assets

^{VII} ROCE-Return On Capital Employed

^{VIII} EVA- Economic Value Added

^{IX} LCP-Life Cycle Profit

^X LCC-Life Cycle Cost

^{XI} engl. RAM ... Reliability (pouzdanost), Availability (raspoloživost) i Maintainability (pogodnost za održavanje)

^{XII} engl. Reliability

^{XIII} EN 13306 iz 2001. godine, izdaje European Committee for Standardization (CEN)

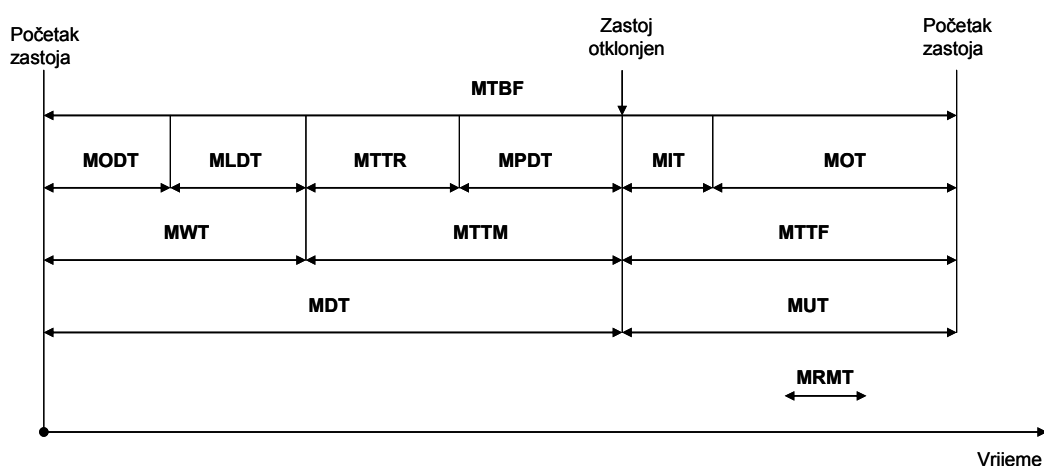
definiciju pouzdanosti, iz priručnika vojske USA br. 217^{XIV} koja kaže: "Pouzdanost je vjerojatnost da će neki uređaj zadovoljavajuće raditi unutar predviđenog vremena, uz definirane radne uvjete"

Raspoloživost je odnos između stvarnog proizvodnog vremena (OT; operating time) i ukupnog raspoređenog proizvodnog vremena, koje je zbroj stvarnog proizvodnog vremena (OT), vremena popravaka (RT; repair time) i vremena tijekom kojeg se čeka (WT; waiting time). Drugim riječima, to je dio ukupnog raspoređenog proizvodnog vremena tijekom kojeg proizvodnja nije bila ometana kvarovima opreme, zastojsima uslijed procesnih poteškoća poput problema s instalacijama, nedostatka materijala, podešavanja, mjerenja, inspekcija, zamjena dotrajalih dijelova, čišćenja i sl.

$$A = OT / (OT + RT + WT) \quad (\%)$$

Performanse pouzdanosti iskazuju se pomoću pokazatelja **srednje vrijeme između kvarova**^{XV}. Za iskaz performansi pogodnosti za održavanje služi pokazatelj **srednje vrijeme popravka**^{XVI}, a za mogućnost davanja podrške **srednje vrijeme čekanja**^{XVII}. Srednja vremena (vidi Slika 5) su naširoko prihvaćeni indikatori za mjerenje raspoloživosti odnosno uspješnosti održavanja pojedinačnog stroja.

$$A = MTBF / (MTBF + MTTR + MWT) \quad (\%)$$



Slika 5: Srednja vremena

^{XIV} MIL HDBK 217

^{XV} engl. Mean Time Between Failures (MTBF)

^{XVI} engl. Mean Time To Repair (MTTR)

^{XVII} engl. Mean Waiting Time (MWT)

Brzina je odnos stvarnog kapaciteta (AC; actual capacity) i ukupnog stvarnog kapaciteta uvećanog za gubitke od jalovog rada, male zastoje i usporenu brzinu (SL; speed losses).

Pojašnjenja vremenskih definicija		
Kratika (eng)	Značenje (eng)	Značenje (hrv)
MTBF	Mean Time Between Failures	Srednje vrijeme između kvarova
MODT	Mean Operative Down Time	Srednje operativno vrijeme zastoja
MLDT	Mean Logistic Delay Time	Srednje logističko kašnjenje
MTTR	Mean Time To Repair	Srednje vrijeme popravka
MPDT	Mean Preventive maintenance Down Time	Srednje vrijeme zastoja zbog preventivnog održavanja
MIT	Mean Idle Time	Srednje vrijeme čekanja na operacije
MOT	Mean Operational Time	Srednje operativno vrijeme
MWT	Mean Waiting Time	Srednje vrijeme čekanja
MTTM	Mean Time To Maintain	Srednje vrijeme održavanja
MTTF	Mean Time To Failure	Srednje vrijeme do kvara
MDT	Mean Down Time	Srednje vrijeme zastoja
MUT	Mean Up Time	Srednje vrijeme ispravnosti
MRMT	Mean Runing Maintenance Time	Srednje vrijeme održavanja u radu

Tablica 1: Pojašnjenja vremenskih definicija

$$S = AC / (AC + SL) \quad (\%)$$

Kvaliteta je odnos između proizvodnje sa zadovoljavajućom kvalitetom iz prvog prolaza (1.Q) i ukupne proizvodnje sa zadovoljavajućom kvalitetom iz prvog prolaza plus odbačena proizvodnja uslijed defekata u procesu ili smanjenih prinosa (RY; reduced yield).

$$Q = 1.Q / (1.Q + RY) \quad (\%)$$

2.5.1.2 Cjelovita učinkovitost opreme- OEE

Ovo vodi do prvog glavnog pokazatelja koji treba uzimati u obzir, a to je cjelokupna učinkovitost opreme^{XVIII} koji prema [8] glasi

$$\text{OEE} = \text{S} \times \text{Q} \times \text{A} \quad (\%)$$

Proizvodnja (P) (prema [9]) je produkt kombinacije akcija koje započinju izoliranim kapacitetom (C), koji pak ovisi o odlukama investicije; prati ga brzina proizvodnje (S) koja ovisi o mogućnostima instaliranoga; slijedi kvaliteta (Q), koja je funkcija sustava upravljanja kvalitetom u poduzeću kao bi se, konačno, dobila raspoloživost (A)^{XIX} koja ovisi o izvođenju održavanja, tj. o gubicima vremena.

$$\text{P} = \text{C} \times \text{S} \times \text{Q} \times \text{A}$$

2.5.1.3 Pokazatelji životnog vijeka materijalne imovine LCC

Druga izuzetno bitna grupa pokazatelja su pokazatelji ekonomike životnog vijeka materijalne imovine. Tu postoje dva dijela:

- benefiti (prihodi u životnom ciklusu opreme^{XX})
- troškovi (troškovi kroz životni vijek opreme^{XXI})

Troškovni dio dalje se može podijeliti na dva dijela:

- trošak stjecanja, kupovine
- trošak vlasništva (održavanja, eksploatacije, ovisni troškovi i sl.)

Troškovi životnog vijeka materijalne imovine prikazani su na Slika 6: Prikaz troškova životnog ciklusa materijalne imovine iz perspektive korisnika".

Za razumijevanje analize orijentirane životnom ciklusu, važno je znanje o fazama životnog ciklusa i utjecaj odluka koje se donose tijekom različitih faza. Već je opisano da se ekonomski naglasak stavlja na fazu razvoja.

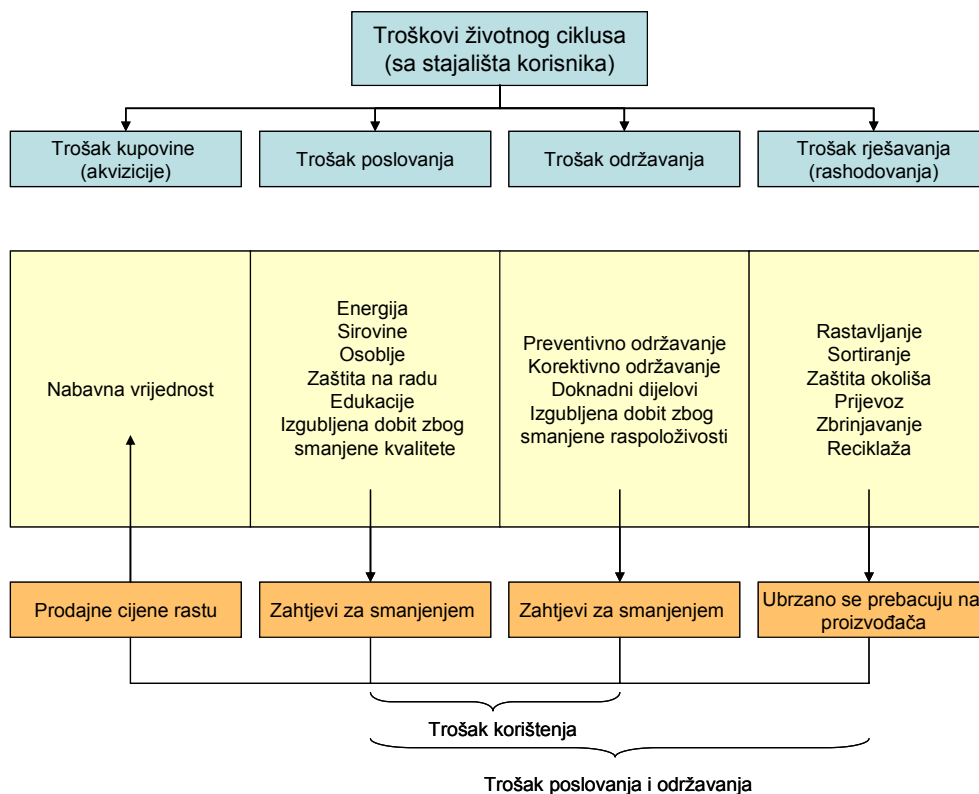
^{XVIII} engl. Overall Equipment Effectiveness (OEE)

^{XIX} engl. Availability (A)

^{XX} engl. Life Cycle Income (LCI)

^{XXI} engl. Life Cycle Cost (LCC)

Troškovi stjecanja u pravilu nastaju tijekom rane faze (prije faze dizajna u sklopu razvoja) dok se troškovi vlasništva, kao i prihodi, javljaju kasnije. Krucijalno je shvatiti da su budući prihodi i troškovi vlasništva zaokruženi već u najranijoj fazi životnog ciklusa opreme/sustava. Prihodi životnog ciklusa uvelike su povezani sa karakteristikama materijalne imovine poput kvalitete te stupnja iskorištenja imovine.




Slika 6: Prikaz troškova životnog ciklusa materijalne imovine iz perspektive korisnika

Gospodarenje imovinom u fazi razvoja bazira se na tri komponente, kao što je prikazano na Slika 7. Trokutom su povezana tehnička razmatranja i shvaćanja s elementima troškova životnog ciklusa. Tehnička prosuđivanja računaju s isporukom i raspoloživošću, inženjeringom i pouzdanošću te s operabilnošću i pogodnosti za održavanje, a predstavljena su na vrhovima trokuta. Veza između njih uspostavlja se na slijedeći način:

- ustanoviti što je potrebno isporučiti i što to znači za sustav te utvrditi njegovu potrebnu raspoloživost
- upoznati se s postavljenom raspoloživošću, s potrebnim sustavom podrške (inženjering, oprema i sl.) te kako dobro bi to moglo funkcionirati, tj. upoznati se sa njegovom pouzdanošću

- za zahtijevanu imovinu definirati strategiju rada i održavanja te kako bi dobro to moglo funkcionirati, tj. njezinu operabilnost i pogodnost za održavanje
- razmotriti kako se sve zajedno uklapa u poslovne ciljeve, a ukoliko nije kompatibilno, prilagođavati dok se ne dođe do mogućeg optimuma.



Graf 1: Važnost poznavanja utjecaja troškova životnog ciklusa na faze životnog ciklusa [11]

Proces je usredotočen na minimaliziranje budućih izdataka i troškova prekida poslovanja koji su u kontekstu imovine povezani s neraspoloživošću. Izdaci, kako je već napomenuto, počivaju na dva uzroka: kapitalni izdaci (troškovi stjecanja) te izdaci tijekom vremena efektuiranja. Na buduće troškove stjecanja, kao element LCC-a, utječu inženjering i odlike pouzdanosti. Planirani troškovi operiranja glavni su LCC element koji će determinirati osobine operabilnosti i pogodnosti za održavanje. Budući troškovi prekida poslovanja (tzv. indirektni troškovi održavanja) u fazi razvoja uvjetuju se definiranjem isporuke i raspoloživosti.

Kako bi se ustanovilo jesu li postignuti najmanji troškovi životnog ciklusa, mora se ustanoviti mjerenje vrijednosti (npr. najmanji ukupni troškovi kroz životni ciklus) koja bi primarno bila vođena ekonomskim promišljanjima u uspoređivanju različitih tehničkih opcija.



Slika 7: povezivanje tehničkih shvaćanja i elemenata troškova tijekom životnog vijeka


2.5.1.4 Ilustracija LCC-a

Napredni proces u fazi razvoja fizičkih sredstava prikazan je na Graf 2. Na ordinatnoj osi troškovi su životnog ciklusa koji se odnose na kapitalne izdatke, buduće operativne troškove i troškove prekida poslovnih procesa. Apscisna je os predstavljena razinom dizajna imovine gdje:

- 1 predstavlja jednostavan dizajn bez redundancije komponenti, s niskim troškovima materijala, slabim osiguranjem i kontrolom kvalitete te s niskom raspoloživošću

- 10 predstavlja napredniji dizajn s visokim stupnjem redundancije komponenti (tj. standby imovine), vrijednim materijalima, dobrim osiguranjem i kontrolom kvalitete te s višom raspoloživošću.

Trend kapitalnih troškova s povećanom razinom dizajna je porast nagiba rasta troškova, kao što je prikazano na Graf 2.



Graf 2: LCC u odnosu na razine dizajna [10]

Trend operacijskih troškova s povećanom razinom dizajna na prvi se pogled čini da je obrnut, što može prevariti. Pri nižim razinama dizajna, imovina zahtjeva više održavanja. Za visoku razinu dizajna, imovina, naime, može imati značajnu razinu održavanja povezanog s većom količinom kompleksnijih sustava i redundancijom.

Izvjesno je da će trend prekida poslovnog tijeka padati do neke konstante s rastom razine dizajna. Pri niskim razinama dizajna, imovina će vjerojatno imati nisku raspoloživost. Kako kompleksnost raste, raste i raspoloživost uz slabljenje benefita uslijed djelovanja umanjene stope prinosa.

Ukupni trend troškova životnog ciklusa fizičkih sredstava jednak je zbroju trendova pojedinačnih troškova kroz životni ciklus. Najniža razina ukupnih troškova ukazuje na najpoželjniji dizajn.

Proces poboljšanja zahtijevanoga dizajna kod pojedinih fizičkih sredstava teče korištenjem iterativnog pristupa kako bi se identificirao puni raspon opcija koje determiniraju trendove. Stoga je u proces odlučivanja nužno sustavno uključivanje svih relevantnih troškova.

Ukoliko se kod početne procjene troškova životnog ciklusa zahtjeva ugradnja neizvjesnosti rezultata, dobro je uključiti Monte Carlo metodu simulacije neizvjesnosti. Kod uznapredovanog vrjednovanja koje razmatra moguću međuovisnost, svakako valja primijeniti model simulacije (za pouzdanost, logistiku, operacije, održavanje).


2.5.1.5 Poveznica RAM pokazatelja i LCC-a

Kao što je već utvrđeno, brojne odluke koje se donose u ranim fazama trajno determiniraju vrijednost troškova cjelokupnog životnog ciklusa. Više od dvije trećine ukupnih troškova životnog ciklusa fiksirani su i poznati već tijekom razvojne faze, iako će izdaci teći bitno kasnije. Šansa je za pravovremenim utjecajem na mogućnost smanjenja troškova životnog ciklusa izlaskom iz razvojne faze bitno smanjena. Na koncu rane faze – faze prije instalacije sustava – prilike za smanjenje troškova životnog ciklusa minimalne su, kako je opisano na Graf 3

Inženjering dimenzionira i oblikuje "troškovni lijevak", dok proizvodnji i održavanju ne preostaje drugo do "ubacivanja" novca sukladno konzumaciji tog lijevka. Naravno, ovisno o postavljenom, kod većeg ili manjeg dijela troškova proizvodnje i održavanja moglo je biti izbjegnuto da "bježe u vjetar" adekvatnim i pravovremenim zahtjevima za RAM pokazateljima. Stoga bitan utjecaj na LCC i RAM pokazatelje od trenutka dovršenja projekta i njegove predaje na upotrebu nije moguć jer matrica ponašanja materijalne imovine definirana i uspostavljena.

Na dugi je rok jedini mogući izlaz iz začaranog kruga gradnje jeftinih postrojenja i njihovih čestih kvarova i popravaka u povećanju produktivnosti, efikasnosti i efektivnosti rada fizičkih sredstava kroz povećane troškove stjecanja, što se može postići na bar dva načina:

- 1) korištenjem tehnika LCC analiza
- 2) ugovornim obvezivanjem projektnih timova da određeni period opslužuju postrojenje kako bi spoznali i osjetili važnost da novi projekti budu dizajnirani s unaprijed postavljenim RAM zahtjevima kao i najmanjim ukupnim troškovima životnog ciklusa (ne samo s najmanjim troškovima stjecanja) jer samo takav pristup osigurava blagostanje vlasnika



Graf 3: Trendovi troškova životnog ciklusa kroz životni vijek fizičkih sredstava [11]

2.6. Proces gospodarenja tehničkim sustavima

Osnovni preduvjeti za uspjeh procesa gospodarenja tehničkim sustavima su:

- Proces mora biti vođen od vrha prema dnu organizacije
- Proces mora biti ostvaren od dna prema vrhu organizacije

Značajke procesa gospodarenja tehničkim sustavima su:

- Obuhvaća projektiranje, nabavu, instalaciju, rad i održavanje
- Zahtjeva mentalitet profitnih centara orijentiranih prema rezultatu, a ne operacije kroz mjesta troška
- Zahtjeva eliminaciju defekata kao jedini način na koji se mogu ostvariti optimalne i održive operacije
- Objedinjuje različite procese održavanja sa postavljanjem financijskih prioriteta kako bi se postigla najveća učinkovitost
- Osigurava procese, tehnike i mjere učinka i na taj način širi odgovornost za stvaranje vrijednosti i povrata sredstava uložениh u imovinu
- Zahtjeva kontinuiran proces poboljšanja
- Povezuje operacije, održavanje, tehničke i financijske funkcije

Uspješan proces gospodarenja tehničkim sustavima zahtjeva promjenu u kulturi, osobnu predanost pojedinca smanjivanju potreba za zahvatima održavanja, a kroz to i snižavanje troškova održavanja. Izuzetno je bitna komunikacija. To posebno dolazi do izražaja kod odnosa između menadžmenta i profesionalaca zaduženih za opremu. Profesionalci su usmjereni na fizička dostignuća opreme i tehnologiju. Mnogi profesionalci su frustrirani jer vjeruju da je njihov prošli i budući doprinos uspjehu i profitabilnosti tvrtke ugrožen odlukama višeg menadžmenta da se usmjeri prema kratkoročnim uštedama. Osim toga većina profesionalaca ima problem kod izražavanja rezultata u financijskim pojmovima koji jedini imaju vjerodostojnost kod višeg menadžmenta. Mnogo se puta dopustilo entuzijastima održavanja da se usmjere na ostvarenje specifičnih ciljeva bez dovoljno discipline i zahtjeva da prikažu kolika je stvarna vrijednost ostvarenja tih ciljeva.

Zbog toga je neophodno da buduće investicije za povećanje produktivnosti budu popraćene sa odgovarajućim financijskim evaluacijama i koje bi opravdale ulaganja. Financijske evaluacije jedini su vjerodostojni pokazatelji koje mogu razumjeti viši menadžeri. Financijski indikatori koji vjerodostojno mogu pokazati koliku vrijednost može donijeti neki projekt su ROI^{XXII} (povrat na investiciju) i NPV (neto sadašnja vrijednost)^{XXIII}.

Čest je slučaj da organizacije usmjerene na smanjenje troškova previde jednu važnu stvar. Nije bitno imati minimalni trošak, već postići maksimalnu vrijednost ili povrat. Zbog toga u financijskom modelu tehnološka unapređenja moraju biti prevedena u financijske pojmove tako da donositelji odluka mogu podržati investiciju i izvući iz nje maksimalnu vrijednost.

Prednosti gospodarenja opremom na način da se potencijalne dobiti prevode u financijske pojmove su:

- Smanjena mogućnost sigurnosnih incidenata, povećana usklađenost za zahtjevima zaštite okoliša
- Povećana raspoloživost i proizvodnja
- Poboljšana kvaliteta
- Smanjena potrošnja energije
- Smanjen opseg aktivnosti održavanja, smanjeni troškovi održavanja

^{XXII} ROI- Return On Investment

^{XXIII} NPV-Net Present Value

- Smanjenje zaliha doknadnih dijelova

2.6.1. Gospodarenje kroz profitne centre

Mnogi profesionalci uočili su potrebu za novom, drugačijom praksom gospodarenja opremom od dosadašnjih. Gospodarenje kroz mjesta troška usklađeno je sa operativnim budžetom. Na taj način izbjegavaju se rizici, ali takav sustav ne stimulira optimizacije (svi znaju za nagrade ukoliko se ne potroši budžet). Nasuprot tome gospodarenje kroz profitne centre orijentirano je na postizanje rezultata, ostvarivanje vrijednosti, poticajno za investicije i prihvaća dodatne troškove kako bi se iskoristile prilike za poboljšanjima. Profitni centri podržavaju agilnost i inicijativu te zahtijevaju odgovornost.

Postoji jasna razlika između mentaliteta "mjesta troška" i "profitnog centra". Orijentacija na mjesta troška nema u sustav ugrađenu stimulaciju za optimizacije. Stimulacija za nepotrošeni budžet mjesta troška često je velika prepreka inicijativama, a znači i manji budžet u budućnosti.

Nasuprot tome kod profitnih centara stimulira se optimizacija. Investicije i dodatni troškovi evaluiraju se sa stajališta ostvarenih rezultata i povrata uložених sredstava. Takav način rada u duhu je pristupa gospodarenja tehničkim sustavima.

2.7. Informacijski sustavi gospodarenja tehničkim sustavima

Informacijski sustavi su krvotok, a ujedno i jedan od najvažnijih proizvoda uspješnog gospodarenja tehničkim sustavima. Sveobuhvatan informacijski sustav ključni je element procesa gospodarenja tehničkim sustavima.

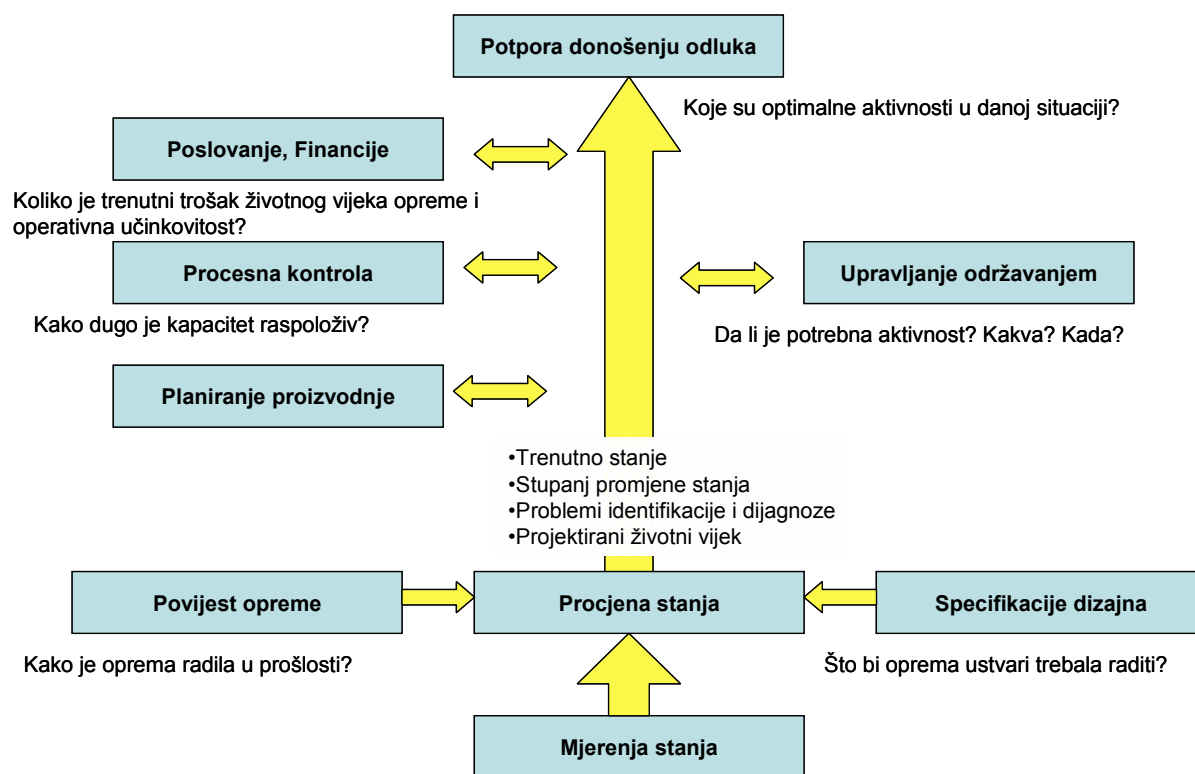
Kao što je vidljivo na Slika 8 informacijski sustav gospodarenja tehničkim sustavima zajedno sa sustavom potpore donošenju odluka mora izmjenjivati informacije sa "Planiranjem proizvodnje i cijele tvrtke" (MES, ERP^{XXIV}), procesnom kontrolom, upravljanjem održavanjem (CMMS), te poslovnim i finansijskim sustavima. U mnogim slučajevima informacijski sustav gospodarenja tehničkim sustavima je jedini izvor mnogih važnih operativnih parametara proizvodne opreme. To uključuje izmjerene

^{XXIV} ERP-Enterprise Resource Planning: Sustav za planiranje, uključuje slijedeće podsustave: marketing, prodaja i kalkulacije, definiranje proizvoda usluga i tehnologije, planiranje i praćenje proizvodnje, lansiranje proizvodnje, planiranje i praćenje održavanja, osiguranje kvalitete, računovodstvo i financije, menadžment i kontroling, nabava, zalihe itd.

parametre stanja, projektirani životni vijek, prisutnost problema, njihova dijagnoza te komponente na koje ti problemi imaju utjecaja.

Korištenjem informacija iz svih tih izvora vodi nas do maksimalne proizvodne učinkovitosti, efikasnog upravljanja održavanjem i doknadnim dijelovima i na kraju maksimalnoj operativnoj profitabilnosti.

Gospodarenje tehničkim sustavima ključno je za osiguravanje raspoloživosti i učinkovitosti opreme (kapaciteta) u toj mjeri da može udovoljiti zahtjevima. Planovi proizvodnje bazirani na faktorima kao što su broj narudžbi, povijesna potražnja, godišnje doba, vrijeme i slično, moraju biti podržani sa planovima kapaciteta proizvodne opreme, bazirano na aktualnom stanju opreme i znanstvenim metodama predviđenom životnom vijeku.



Slika 8: Pojednostavnjena struktura informacijskog sustava gospodarenja imovinom

2.8. Održavanje

Održavanje je ključna komponenta procesa gospodarenja tehničkim sustavima jer osigurava raspoloživost kapaciteta neophodnih za proizvodnju. Održavanje treba promatrati kao investiciju u budući profit koji će se ostvariti kroz osiguravanje kapaciteta, poboljšanu kvalitetu i smanjene operativne troškove. Ukratko optimalno

održavanje i gospodarenje opremom ključni su za ostvarenje profita tijekom životnog vijeka opreme.

2.8.1. Misija održavanja

Koja je točno svrha funkcije održavanja? U okruženju neprekidnih reorganizacija, promjene tehnoloških paradigmi, rastućih očekivanja i pojačanih regulatornih ograničenja sa kojima se održavanje mora nositi i to uglavnom sa velikom hitnošću, vrlo je lako izgubiti kompas. Većina tvrtki donijela je formalne "misije" koje im pomažu u održavanju stabilnog kursa usred savladavanja mnogobrojnih prepreka. Zbog toga je potrebno osmisliti i formalnu "misiju" koja bi na sličan način usmjeravala održavanje.

Zbog čega postoji održavanje? Održavanje postoji zbog materijalne imovine koju je potrebno održavati. Zbog toga "misija" mora odražavati činjenicu da održavanje postoji u prvom redu zbog materijalne imovine. Slijedeća stvar o kojoj je potrebno voditi računa kod kreiranja "misije" je činjenica da je materijalna imovina u funkciji zato jer netko želi sa njom obaviti određeni posao. Drugim riječima od materijalne imovine očekuje se da ispuni specifičnu funkciju ili funkcije. Iz toga slijedi da kada održavamo neko sredstvo, stanje koje želimo zadržati je ono u kojem to sredstvo nastavlja raditi ono što želi njegov korisnik. Zbog toga je u "misiji" potrebno naglasiti da želimo sačuvati ono što sredstvo radi, a ne sredstvo samo zbog sebe.

Nadalje u misiji je potrebno dati naglasak korisnicima, to jest vlasnicima imovine. Održavanje će udovoljiti vlasnike materijalne imovine tako što će osigurati da njihova imovina ostvari povrat sredstava uložених njezinu nabavu. Naposljetku održavanje zadovoljava i društvo u cjelini jer vodi brigu o tome da imovina svojim kvarom ne ugrožava okoliš.

Kada se stvari ne bi kvarile ne bi postojala potreba za održavanjem. Prema [12] bit tehnologije održavanja je u pronalaženju i primjeni odgovarajućih tehnika rješavanja kvarova: predvidivo održavanje, preventivno održavanje, pronalaženje grešaka, korektivno održavanje, jednokratne promjene dizajna ili načina rada opreme.

Svaka od ovih kategorija pruža nam veliki broj opcija. Glavni izazov sa kojim se održavanje danas suočava nije samo u tome da se nauči koje su to opcije, već je u tome da se ustanovi koja od tih opcija je vrijedna primjene u vlastitoj organizaciji. Ukoliko se odabere ispravno, moguće je poboljšati učinak opreme, te u isto vrijeme smanjiti troškove održavanja. U slučaju krivog odabra samo se stvaraju novi problemi

dok postojeći postaju sve gori. "Misija" mora podsjećati na obavezu ispravnog odabira od cijelog niza opcija.

Kada razmatramo razne mogućnosti rješavanja kvarova, moramo imati na umu da kvarovi imaju posljedice, od troškova popravka, sigurnosti ljudi i okoliša, količine i kvalitete proizvoda, odnosa sa kupcima i korisnicima gotovog proizvoda i operativnih troškova. Ozbiljnost i učestalost kojom kvarovi izazivaju neke od ovih posljedica određuje koju tehniku otklanjana grešaka vrijedi primijeniti. U misiji mora biti naglašena ključna uloga koju posljedice kvara imaju u održavanju.

Također je potrebno naglasiti da su resursi u većini slučajeva prilično ograničeni. Najuspješniji održavatelji su oni koji primjenjuju potrebne resurse (ljude, doknadne dijelove, alate) na troškovno najefikasniji način. To ne znači da treba biti toliko jeftin da se u pitanje dovede dugotrajna funkcionalnost opreme. Cilj je imati minimalan trošak vlasništva nad opremom tijekom njenog životnog vijeka, a ne samo u tekućem obračunskom razdoblju.

Bitno je naglasiti da održavanje ovisi o ljudima, ne samo održavateljima, već i o operaterima, konstruktorima i dobavljačima. Neophodno je istaknuti potrebu za stvaranjem okruženja u kojem će svi koji imaju bilo kakve veze sa opremom imati zajedničko razumijevanje što je potrebno napraviti i da su spremni to provesti.

Prema tim kriterijima "misija" održavanja bi trebala sadržavati slijedeće odrednice:

Očuvati funkcionalnost materijalne imovine tijekom njenoga tehnološkog životnog vijeka, tako da zadovoljimo vlasnike, korisnike i društvo u cjelini, odaberemo i koristimo troškovno najefikasnije tehnike otklanjanja grešaka i njihovih posljedica uz aktivnu podršku svih.

2.8.2. Razvijanje strategije održavanja

Nakon definiranja misije održavanja potrebno je izraditi strategiju kojom će biti moguće ostvariti zadanu misiju. S obzirom na svakodnevni pritisak a kojim se menadžeri održavanja suočavaju, prvo pitanje je odakle početi? Da li kupiti novi sustav upravljanja održavanjem? Provesti reorganizaciju? Investirati u gomilu dijagnostičke opreme? Srušiti cijeli pogon i izgraditi novi?

Odgovor se nalazi u početnom dijelu misije koji govori kako je potrebno " *Očuvati funkcionalnost materijalne imovine tijekom njenoga tehnološkog životnog vijeka*". To je moguće samo ako su točno definirane funkcije opreme koje želimo sačuvati, a isto

tako moraju biti definirane i greške. Tek tada je moguće razgovarati o uzrocima i posljedicama svake greške na opremi.

Nakon što su definirani uzroci i posljedice grešaka moguće je procijeniti utjecaj svake od njih. Tada se može odrediti pripadnost jednoj od pet grupa za otklanjanje pogrešaka (predvidivo održavanje, preventivno održavanje, pronalaženje grešaka, korektivno održavanje, jednokratne promjene dizajna ili načina rada opreme). Proces u kojemu smo odlučili što je potrebno poduzeti kako bi očuvali funkcionalnost opreme naziva se identifikacija posla. Kada su jasno identificirani zadaci koji se moraju provesti kako bi ispunili zahtjeve održavanja na opremi, moguće je identificirati potrebne resurse za obavljanje svakog zadatka. Resursi su ljudi i stvari, a prema tome moramo odlučiti tko će obaviti određeni zadatak, kakav trening mu je za to potreban i koji su mu dijelovi, alati i dijagnostička oprema nužni.

Tek kada smo potpuno sigurni koji su nam resursi neophodni, možemo pristupiti odabiru sustava kojim ćemo upravljati dotičnim resursima na način da se obave svi zadaci i da se očuva funkcionalnost opreme.

Ukratko možemo reći da razvoj strategije održavanja ima tri ključna koraka [13]:

1. Određivanje zahtjeva za održavanjem na svoj opremi
2. Donošenje odluke o resursima potrebnim da bi se ispunili zahtjevi za održavanjem
3. Odlučiti koji sustav je potreban za gospodarenje tim resursima

Ukoliko napravimo pogrešku u prvom koraku, tada nećemo imati odgovarajuće resurse niti odgovarajući sustav.

Česta pogreška koja se događa je obrnuti redoslijed aktivnosti. Najprije se odabere sustav i resursi, a zatim oni se ispunjavaju samo oni zahtjevi koje ti resursi mogu ispuniti.


2.8.2.1 Revizija strategije

Vrlo bitna stvar koja se često zaboravlja općenito u vezi strategije je praćenje izvršenja strategije i revizija strategije. Bilo koja strategija je mrtvo slovo na papiru ukoliko se ne prati i mjeri njezino ostvarenje i revizija temeljem rezultata ostvarenja.

Postoje i alati koji podržavaju kompletan strateški proces (BSC-Sustav uravnoteženih ciljeva). Više o tome u poglavlju 2.9.1 "Sustav uravnoteženih ciljeva-BSC".


2.8.3. Vrste održavanja

Pojednostavnjeno gledano funkcija održavanja sastoji se od dviju glavnih aktivnosti: neplansko ili reaktivno održavanje, te plansko održavanje. Plansko održavanje definirano je kao u potpunosti isplaniran posao uvršten u raspored aktivnosti. Povećanje pouzdanosti ustvari je kombinacija održavanja i inženjeringa. Održavanje prema vremenskim intervalima, održavanje po stanju i proaktivno održavanje uvijek su planski. Održavanje prema vremenskim intervalima, održavanje prema stanju i predvidivo održavanje nazivaju se još i preventivno održavanje. Razvoj procesa održavanja odvijao se od korektivnog održavanja prema održavanju po stanju i proaktivnom održavanju.



Slika 9: Usklađenost procesa održavanja sa gospodarenjem tehničkim sustavima [4]

Ovisno o kriterijima definiranim u poglavlju 2.8.1 "Razvijanje strategije održavanja" odabiremo jedan od pristupa održavanju (vidi Slika 10: Razvoj pristupa i koncepcija održavanja). Iako se njihov razvoj odvijao tijekom godina, u primjeni imamo sve koncepcije ili čak njihove kombinacije.



Slika 10: Razvoj pristupa i koncepcija održavanja [14]

Korektivan pristup je najstariji i radi se o zahvatima koji se izvode nakon što je došlo do kvara. U *preventivnom* pristupu radovi se obavljaju prema zacrtanom planu prije nego nastane kvar. Osnova *terotehnoškog* pristupa je da stručnjaci održavanja moraju svojim znanjem izravno ili posredno sudjelovati u svim fazama životnog vijeka opreme. U *logističkom* pristupu osnovna ideja je učiniti sve u fazi projektiranja i proizvodnje opreme kako bi oprema imala visok stupanj pouzdanosti i bila pogodna za održavanje. *Održavanje po stanju* dio je preventivnog održavanja čiji je nastanak omogućen razvojem elektronike i dijagnostičkih uređaja, a značajka je da se zahvati održavanja obavljaju na temelju rezultata dobivenih mjerenjima koja su definirana u vremenskim intervalima. *Plansko* održavanje je kombinacija preventivnog i korektivnog održavanja u omjeru koji najbolje odgovara određenom poduzeću.

TPM [15] ili cjelovito produktivno održavanje nastalo je u Japanu (automobilska industrija-Toyota), a osnovna ideja je povjeravanje niza zahvata održavanja rukovateljima opreme, koji čine male grupe motivirane za rad, jer o raspoloživosti opreme ovisi njihova učinkovitost, a preko toga i zarada.

Ekspertni sustavi održavanja pojavljuju se 80' godina na obradnim centrima i procesnim postrojenjima, gdje je na temelju kreirane baze podataka bilo moguće doći do informacija o potrebnim zahvatima održavanja.

Samoodržavanje je koncepcija u koju je uključen jedan ili više ekspertnih sustava, koji daju informaciju o kvaru robotiziranoj liniji sastavljenoj od modula. Ta informacija inicira zamjenu modula koji obavi robot.

2.9. Alati i metodologije korišteni u gospodarenju tehničkim sustavima

U gospodarenju tehničkim sustavima koriste se mnoge tehnike i alati. Odabrao sam dva relativno često primjenjivana. Prvi je BSC, alat za strateško upravljanje tvrtkom koji je i pronašao je primjenu u gospodarenju tehničkim sustavima. Druga metodologija je 6σ ili na engleskom "six-sigma".

2.9.1. Sustav uravnoteženih ciljeva-BSC

U današnjem globalnom poslovnom okruženju strategija je važnija nego ikad. Iako je većina svjesna te činjenice, istraživanja su pokazala da veliki broj kompanija nije uspio u provedbi svojih strategija. Uzrok tome leži u činjenici da većina kompanija još uvijek koristi slijedeće principe: proces upravljanja od vrha prema dnu, financijski orijentiran, taktički vođen. Ti principi osmišljeni su za vođenje kompanija koje su sada stvar prošlosti.

U hrvatskoj je ta situacija još izraženija. Prelaskom hrvatskog gospodarstva na tržišno poslovanje, financijski rezultati postali su jedino mjerilo uspjeha menadžmenta kompanije.

Balanced Scorecard (skraćeno BSC) ili sustav uravnoteženih ciljeva metoda je koja pomaže ne samo u formuliranju strategije, nego i u provođenju i mjerenju uspješnosti provedbe.

2.9.1.1 Stvaranje strateški vođene organizacije

2.9.1.1.1 Razlozi uvođenja

Studija koja je obuhvatila 275 menadžera [1] pokazala je slijedeće: "*sposobnost provođenja strategije važnija je od same strategije*", kao i da je implementacija strategije najvažniji utjecajni čimbenik kod evaluacije menadžmenta i korporacije u cjelini. To može izgledati iznenađujuće, jer su zadnja dva desetljeća

teoretičari menadžmenta, konzultanti i poslovna literatura fokusirani na samo kreiranje strategija koje bi trebale same po sebi generirati superiorno poslovanje.

U ranim 80' menadžment konzultanti proveli su istraživanje koje je pokazalo da je samo 10% kvalitetno kreiranih strategija uspješno implementirano. Studija koju je proveo "*Fortune magazine*" 1999 o najvećim promašajima poznatih izvršnih direktora pokazala je da je većina njih mislila da je dobro formulirana strategija sve što je potrebno za uspjeh.

- Zašto organizacije imaju problema kod implementacije uspješno formuliranih strategija? Jedan od problema leži u činjenici da se strategije kao jedinstveni i održivi način na koji kompanija kreira vrijednost mijenjaju, ali alati za "mjerjenja" strategija nisu popratili taj razvoj.

U vrijeme dok je ekonomijom dominirala materijalna imovina, financijski pokazatelji u bilanci stanja bili su adekvatni za praćenje investiranja u opremu, proizvodne pogone i inventar. Ali današnja ekonomija gdje je nematerijalna imovina postala glavni izvor kompetitivne prednosti, narasla je potreba za alatom koji bi pratio imovinu baziranu na znanju.

Jedan od izvora problema koji je nastao kada su kompanije pokušale upravljati svojom nematerijalnom imovinom baziranom na znanju su centralizirane organizacije sa velikim funkcijama podrške. Strategija razvijena na vrhu kompanije implementirana je kroz sustav naredba-kontrola. Takav način je bio spor zato jer je menadžment mogao provoditi jedino taktičke promjene kroz "spore" sustave kao što je budžet. Tako se ukazala potreba za novim sustavom upravljanja koji bi bio baziran na upravljanju strategijom a ne samo taktikom.

Balanced Scorecard (BSC^{xxv}) ili sustav uravnoteženih ciljeva nastao je kao odgovor na te probleme.

2.9.1.1.2 Zašto financijski indikatori mogu biti pogrešni?

Financijski pokazatelji opisuju ishod, ali ne i posljedice prošlih akcija. Oni su ustvari "indikatori s kašnjenjem" (*eng. lag*). Oslanjanjem isključivo na financijske pokazatelje promovira se kratkoročno ponašanje, kojim možemo žrtvovati dugoročne potencijale.

^{xxv} Radi jednostavnosti umjesto Balanced Scorecard, ili sustav uravnoteženih ciljeva biti će korištena kratica BSC

BSC sustav zadržao je financijske pokazatelje, ali im je pridružio "vodeće" (*eng. leaad*) pokazatelje kojima se mjere potencijali koji mogu kreirati buduće financijske rezultate.

Koji su to pokazatelji kojima možemo izmjeriti buduće rezultate? Ako financijski pokazatelji navode organizacije da čine pogrešne stvari, koji pokazatelji bi ih natjerali da vuku prave poteze? Potrebno je mjeriti strategiju!

Treba voditi računa o tome da svi financijski i nefinancijski pokazatelji trebaju biti derivirani iz vizije i strategije.

2.9.1.2 Principi strateški vođene organizacije

U prvoj polovici 90' godina neke su kompanije u USA uvele BSC. Bilo je izuzetno uspješnih slučajeva, npr. Chemical (Chase) Retail Bank imao je 1996. godine 19 puta veći profit nego 1993. godine kada je započeo sa uvođenjem BSC-a [16].



Slika 11: Principi strateški vođene organizacije

Na koji način su postigli takve rezultate? BSC je omogućio kompanijama da koncentriraju i prilagode svoj tim izvršnih direktora, poslovna područja, kadrovske poslove, IT i financijske resurse svojoj strategiji.

Iako su organizacije imale razne pristupe uvođenju BSC, uočeno je pet osnovnih zajedničkih principa (vidi Slika 11).

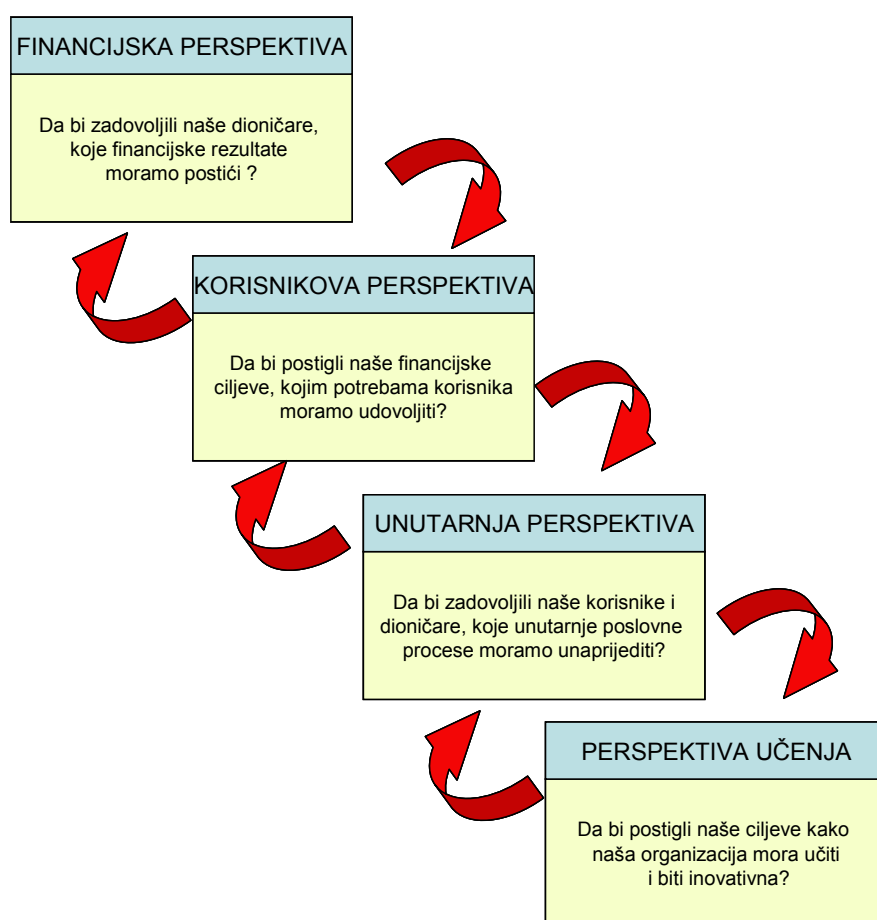
- Translatirati strategiju u operativne pojmove
- Prilagoditi organizaciju strategiji
- Definirati strategiju kao svakodnevni posao svih

- Definirati strategiju kao neprekidni proces
- Pokrenuti promjene pod vodstvom top menadžmenta

2.9.1.2.1 Translatiranje strategije u operativne pojmove

Brzina kojom su nove strategije polučile rezultate pokazuje da se uspjeh nije dogodio zbog značajnih novih proizvoda, usluga, kapitalnih investicija ili razvoja novih nematerijalnih tj. "intelektualnih dobara". Naravno da su kompanije radile sve navedeno, ali u dvije godine od tih aktivnosti nije moguće očekivati tako veliki povrat.

Arhitektura BSC-a translatira strategiju u operativne pojmove




Slika 12: Arhitektura BSC-a

Rezultati su postignuti zbog boljeg korištenja postojećih sposobnosti i imovine (materijalne i nematerijalne). Nove strategije oslobodile su potencijale "skriven" u organizaciji.

BSC osigurava okvir koji opisuje i komunicira strategiju na dosljedan i jednostavan način. To se radi pomoću "strateške mape".

Strategiju je moguće opisati kao niz uzročno-posljedičnih veza (vidi Slika 12) Strateška mapa organizirana je na slijedeći način. U "redcima" se nalaze četiri perspektive, do u stupcima imamo "strateške teme". Perspektive i njihova međusobna ovisnost već su prikazane u (Slika 12), dok su elementi "strateške teme" prikazani na Slika 13.




Slika 13:Komponente BSC-a

Na strateškoj mapi uobičajeno je imati do maksimalno četiri strateške teme (vidi Slika 14)

Na strateškoj mapi prikazuje se uzročno posljedična veza između ciljeva, dok se mjere, rezultati, i inicijative vode na posebnim dokumentima. Moguće je da postoji međusobna ovisnost ciljeva koji se nalaze u raznim strateškim temama.

Strategija translatairana u logičnu arhitekturu strateške mape postaje polazna točka za poslovna područja i za sve zaposlenike.



Slika 14: Primjer strukture strateške mape

2.9.1.2.2 Usklađivanje organizacije sa strategijom

Ostvarivanje sinergija je glavni i sveobuhvatni cilj svake organizacijske strukture. Organizacije se sastoje od brojnih sektora, poslovnih područja i raznoraznih odjela, a svaki od njih ima svoju strategiju. Da bi ukupni rezultat neke organizacije bio veći nego što je suma pojedinih dijelova, individualne strategije moraju biti povezane i integrirane. *Korporacija*^{xxvi} definira veze koje bi trebale stvoriti sinergije, te osigurava da se veze stvarno i ostvare. To naravno nije nimalo lako niti jednostavno.

Tradicionalno, organizacije su posložene oko specifičnih funkcija kao što su financije, proizvodnja, marketing, prodaja, inženjering i nabava. Svaka funkcija ima svoje vlastito znanje, specifičan jezik i kulturu. Nastaju funkcijski "silosi" koji su glavna prepreka implementaciji strategije, jer u većini organizacija postoji problem komunikacije i koordinacije između funkcija. Strateški vođena organizacija ruši te barijere. Top menadžment zamjenjuje formalne linije raportiranja sa strateškim temama i prioritetima koje omogućuju da bude jasno prenesena poruka i definirani prioriteti kroz razne funkcije. To ne znači da je potrebno kreirati novu organizacionu strukturu. Poslovne jedinice i funkcije podrške povezane su strategijom kroz zajedničke teme i ciljeve koje se nalaze u njihovim BSC-ovima.

U svim uspješnim slučajevima kompanije su koristile BSC koordinirano kroz cijelu organizaciju, te na taj način osigurale je cjelina veća od sume pojedinih dijelova.

^{xxvi} Pod pojmom korporacija podrazumijeva se onaj dio kompanije koji upravlja ostalim poslovnim područjima, a osim same uprave obično sadrži i neke funkcije podrške

2.9.1.2.3 Definirati strategiju kao svačiji svakodnevni posao

U organizacijama koje su uvele BSC glavni izvršni direktor i ostatak top menadžmenta nisu mogli implementirati BSC sami. Zahtijevali su aktivni doprinos svih zaposlenika. U strateški vođenoj organizaciji neophodno je da svi zaposlenici shvate strategiju i da provode svoje dnevne poslovne aktivnosti na način koji će doprinijeti uspjehu njihove strategije. Tu se ne radi o hijerarhijskoj odozgo prema dolje odgovornosti, već je riječ o komuniciranju strategije odozgo prema dolje. Top menadžment koristi BSC kao pomoć kod komuniciranja i educiranja organizacije o novoj strategiji. Često se znala čuti primjedba, da ukoliko je strategija poznata svima u organizaciji, postoji velika opasnost od curenja vrijednih informacija konkurenciji. Najbolji odgovor na to pitanje dao je Brian Baker iz Mobil-a "Poznavanje naše strategije konkurenciji neće puno pomoći, ukoliko ju nisu u stanju provesti, a s druge strane mi ne možemo provesti našu strategiju ukoliko ona nije poznata svakom zaposleniku". "To je rizik koji moramo preuzeti".

Da bi shvatili strategiju zaposlenici su morali naučiti o segmentaciji tržišta, sustavu obračuna varijabilnih troškova, marketingu, itd. Umjesto da pretpostave kako su zaposlenici nesposobnosti za shvaćanje tih ideja, kompanije su provele aktivnosti edukacije o navedenim strateškim komponentama na svim nivoima.

Nakon toga slijedilo je kaskadiranje kompanijskog BSC po poslovnim područjima i nižim organizacionim jedinicama, do te mjere da su postavljani i osobni ciljevi, na temelju kojih je kasnije obavljana procjena učinka.


Ciljevi nisu kaskadirani kroz organizaciju kroz "zapovjedni lanac" kao što je uobičajeno, umjesto toga komunicirana je strategija. Nakon toga su pojedinci i odjeli na nižim nivoima razvijali svoje vlastite ciljeve u skladu sa općim prioritetima.

Na kraju je i sustav kompenzacija povezan sa BSC-ima. Zbog toga su zaposlenici iskazali dodatni interes za ostale komponente strategije i za mjere po kojima ih se ocjenjuje. Kod kompenzacije bitno je za napomenuti da je u određenim omjerima ovisila o BSC-u kompanije, divizije, odjela, što je stimuliralo poboljšanje suradnje između odjela i na taj način dalo doprinos ukupnom rezultatu kompanije. Na taj način strategija uistinu postaje dnevni posao svakog zaposlenika.

2.9.1.2.4 Definirati strategiju kao kontinuirani proces

Kod većine organizacija menadžment proces formiran je oko budžeta operativnog plana. Mjesečni sastanci posvećeni su usporedbi plana i ostvarenja,

analizama prethodnih rezultata i akcijskim planovima za otklanjanje eventualnih odstupanja. Takav pristup je sasvim u redu, taktički menadžment je neophodan. Problem je u tome što je za većinu organizacija to sve. Nema sastanaka na kojima menadžment razgovara o strategiji. Da li je onda čudno što takve kompanije ne uspijevaju sa implementacijom svojih strategija?



Slika 15: Strategija kao kontinuirani proces

Kompanije koje su uspješno implementirale BSC, uvele su proces kojim upravljaju provođenjem strategije. Povezali su taktičko upravljanje sa provođenjem strategije (na mjesečnim sastancima analizira se budžet, ali i radi pregled ostvarenja rezultata po BSC-ima). U procesu upravljanja provedbe strategije pojavila su se tri ključne teme:

- povezivanje strategije sa procesom donošenja budžeta
- kratki sastanci top menadžmenta sa temom analize ostvarenja strategije
- proces učenja i prilagođavanja strategije

Povezivanje strategije sa procesom donošenja budžeta:

BSC je osigurao kriterije za evaluaciju potencijalnih investicija i inicijativa. Kompanije su otkrile da su im potrebna dva budžeta: operativni i strateški. Postoji bitna razlika između ta dva budžeta. Kao što BSC pokušava zaštititi dugoročne inicijative od kratkoročnih suboptimizacija, tako i proces budžetiranja mora zaštititi dugoročne inicijative od pritiska za postizanjem boljih kratkoročnih finansijskih rezultata.

Kratki sastanci top menadžmenta sa temom analize ostvarenja strategije

Uvedeni su na mjesečnoj ili kvartalnoj bazi, kako bi se diskutiralo o BSC-u i kako bi menadžeri mogli izmijeniti svoja promišljanja o strategiji. U nekim kompanijama su teme tih sastanaka javno izvještavane po kompaniji.

Proces učenja i prilagođavanja strategije

Početni BSC-i predstavljali su hipoteze o strategiji, bili su trenutku donošenja najbolje moguće procjene aktivnosti koje će osigurati dugoročni finansijski uspjeh. Nakon što je proces zaživio i počele su dolaziti povratne informacije, organizacije su došle u mogućnost testiranja hipoteza postavljenih u strategiji. Ispitivana je i eventualna pojava novih prilika koje nisu postojale u trenutku donošenja strategije. Na taj način su ideje i učenje postale neprekidni proces u organizaciji.

2.9.1.2.5 Pokretanje promjena pod vodstvom top menadžmenta

Prva četiri principa usredotočila su se na BSC kao alat i njemu pripadajuće procese. Potrebno je naglasiti da proces i alat nisu dovoljni kako bi neka organizacija postala strateški vođena. Više puta je dokazano da je jedini i najvažniji preduvjet za uspjeh, odgovornost i aktivno sudjelovanje top menadžmenta. Strategija zahtijeva promjenu u svim dijelovima organizacije. Neophodan je timski rad kod koordinacije tih promjena. Pored toga implementacija strategije zahtijeva kontinuiranu pažnju i praćenje inicijativa i rezultata u usporedbi sa zacrtanim ciljevima. Ako oni koji su na vrhu nisu energični vođe procesa, neće se dogoditi promjene, strategija neće biti implementirana, a prilika za ostvarenje vrhunskih rezultata biti će propuštena.

Uspješan BSC program započinje sa spoznajom da to nije još jedan sustav praćenja i izvještavanja, već da je to proces promjene. Na početku naglasak je na

mobilizaciji i stvaranju momentuma kako bi pokrenuli proces. Jednom kad je organizacija mobilizirana, fokus prelazi na upravljanje s naglaskom na fluidni timski pristup nestrukturirane prirode prelaska na novi model. Tijekom vremena ovaj pristup evoluirao u novi "strateški sustav upravljanja" koji institucionalizira nove kulturne vrijednosti i nove strukture u novi sustav upravljanja. Ukupno trajanje ovih faza iznosi dvije do tri godine.

2.9.1.3 Uloga BSC-a u upravljanju tehničkim sustavima

BSC može donositi višestruke koristi upravljanju tehničkim sustavima. Osnovna prednost BSC je da ne gleda rezultate kroz financijske pokazatelje i kratkoročne uštede, već daje prioritete važnim projektima kojima podupiremo izvršenje strategije i ulažemo u budućnost. Tako kroz sustav BSC-a dobijemo dugoročne ciljeve koji usmjeravaju prema određenom načinu gospodarenja tehničkim sustavima.

2.9.2. Šest Sigma-6σ

Šest sigma je postala metodologija za poboljšanje kvalitete i konzistentnosti procesa [17]. Osnovna pretpostavka, pokretač 6σ koncepta je ta da je procesna varijabilnost (raznolikost) neprijatelj kvalitete. Što je više varijacija u proizvodnji i na proizvodu, manji je broj jedinica koje će raditi i zadovoljavati svrhu kako bi prema dizajnu trebale. Misija je 6σ da eliminiranjem korijena problema (root causes) neumorno smanjuje varijabilnost koja uzrokuje defekte proizvoda i procesa.

Implementacija 6σ predstavlja zaokret u organizacijskoj kulturi kompanije i okretanje pragmatičnim rješenjima za unaprjeđenje prihoda i smanjenje troškova poslovanja, iako postizanje 6σ najčešće nije primarni cilj ili individualni projekt već menadžment, u namjeri da ostvari definirane rezultate, poseže za ovim konceptom koji pruža mogućnosti značajnih ušteda.

6σ je ustanovljen kao sustav osiguranja kvalitete, a promoviran kao TQM tip inicijative. 6σ koristi tri cjelovita pokazatelja: ukupan prinos, trošak loše kvalitete^{xxvii} i kapacitet tj. brzina. Kapacitet se mjeri na isti način kao i kod OEE-a ili iskorištenosti imovine, ukupan je prinos ukupan broj defektnih proizvoda podijeljen s ukupnim

^{xxvii} engl. Cost Of Poor Quality (COPQ)

brojem proizvedenih jedinica. Trošak loše kvalitete ili COPQ je trošak promašaja da se proizvede i isporuči 100% kvalitetnih proizvoda iz prvog prolaza. Trošak promašaja uključuje:

- unutrašnje troškove pogrešaka: rad i materijal konzumiran u rasapu, rasturu, povratu; ponovne dorade koja uključuje troškove dodanog materijala, rukovanja i troškove vezane za produženi proizvodni ciklus; neplanskih zastoja, gubitaka prinosa
- troškove osiguranja kvalitete uključujući inspekcije te troškove ljudi i opreme vezane za testiranje kvalitete i audite
- troškove unaprijeđenja nedovoljne kvalitete: uključujući opremu i programe
- vanjske troškove pogrešaka: pritužbe u garantnom roku uvećane za troškove terenskih servisa
- troškove izgubljenih prilika: proizvodnje više proizvoda na istoj imovini, odanost kupaca i gubitak prodajnih prilika zbog nedostatne kvalitete
- miješanja i specijalno rukovanje, pritužbe, kredite i specijalan prijevoz. Mnoge kompanije imaju COPQ vrijednost 25% od prodaje. Šest sigma kompanije obično očekuju da ovaj broj prepolove.

Tehnički promatrano, 6σ jednako 3,4 defekata na milijun pokušaja. Većina je današnjih industrija na razini Dvije sigme (2σ), koja proizvodi 308.537 defekata na milijun pokušaja. Jedino zračna industrija, uslijed važne sigurnosti, ima performanse iznad 6σ , dok popratne djelatnosti, kao manipuliranje prtljagom i slično, rade na 2σ . Čak i bolnice rade na oko 3σ .

Proširena na poslove i procese održavanja s ciljem povećanja efikasnosti i zadovoljstva korisnika te minimaliziranje zastoja, proces 6σ uključuje:

- definiranje projekata poboljšanja baziranih na poslovnim ciljevima, potrebama korisnika i povratnoj vezi; definiranje karakteristika kritičnih za kvalitetu
- mjerenje procesa kritičnih za kvalitetu kao i defekata povezanih s njima
- analiza uzroka generiranja defekata
- poboljšanje procesa kako bi se zadržao unutar zahtijevanog ranga
- kontrola kako bi se uvjerilo da varijable ostaju unutar prihvatljivih "gabarita".

2.10. *Pristupi gospodarenja tehničkim sustavima-zaključak*

Gospodarenje tehničkim sustavima je podložno je stalnim promjenama i unapređenjima. Pojavljuju se novi koncepti, primjenjuju se novi alati i metodologije a sve to sa ciljem što uspješnijeg gospodarenja tehničkim sustavima. Svaki pristup ima svoje prednosti ali i nedostatke ovisno o tome gdje i kako se primjenjuje. Ako je briga o gospodarenju tehničkim sustavima u tvrtki prepoznata kao bitan čimbenik uspjeha pridaje joj se značaj i vodi se korištenjem nabrojanih sustava i alata. Ukoliko to nije slučaj opet se parcijalno koriste neke od ovih metoda. Uglavnom svatko treba sam odlučiti što će i kako raditi, a navedeni trendovi, alati i metodologije mogu usmjeravati i pomagati u učinkovitijem gospodarenju tehničkim sustavima.

3. POSLOVNA INTELIGENCIJA

U ljudskoj povijesti ostali su zabilježeni mnogi slučajevi dobro ali i loše donošenih odluka. Kako je Paris pobijedio Ahila, dotada neranjivog i nepobjedivog ratnika? Imao je informaciju o "Ahilovoj peti" i donio odluku kako iskoristiti tu slabost (lukom i strijelom naravno). Naravno ovdje se radi o mitu, a svrha svakog mita jest izvlačenje jedne univerzalne pouke.

Tako i jedan od gurua "Competitive Intelligence-a [18] " Ben Gilad prilikom analize konkurenata propisuje pronalaženje "Crvenog gumba^{xxviii}". Što predstavlja "Crveni gumb"? Ništa drugo nego "Ahilovu petu".

U današnje doba na tržištu se odvijaju mnoge bitke. Svatko želi pronaći protivnikovu Ahilovu petu, a isto tako i svoju, kako bi ju zaštitio na određeni način. Sve to omogućuje poslovna inteligencija.

U ovom radu koristit ću mnoge pojmove koji su u svakodnevnoj upotrebi u originalnoj, engleskoj verziji. Kada sam pogledao postojeće dostupne prijevode ovih pojmova na hrvatski jezik, nisu mi na prvi pogled bili tako poznati kao ti pojmovi na engleskom. Kako ne želim upotrebljavati engleske riječi za one pojmove koji postoje na hrvatskom, radi boljeg razumijevanja i praćenja ovog rada najprije dajem usporedni pregled korištenih pojmova i njihove definicije.

Hrvatski	Engleski	Kratice	Definicija/Opis
Poslovna inteligencija	Business Intelligence	BI	1)Korištenje kolektivnog znanja organizacije sa ciljem postizanja konkurentske prednosti 2)Pojam koji objedinjava DW, DM, OLAP i ostale pripadajuće metodologije
Sustav potpore donošenju odluka	Decision Support System	DSS	Posebna klasa računalnih informacijskih sustava koja pomaže u donošenju poslovnih i organizacionih odluka
Skladište podataka	Data Warehouse	DW	Kopija transakcijskih podataka posebno strukturiranih za upite i izvještavanje
Kopanje podataka	Data Mining	DM	Analiza na prvi pogled neprimjetnih veza među podacima pomoću sofisticiranih statističkih procedura

^{xxviii} Red Button je definiran kao osjetljivo područje. "Aktiviranje" crvenog gumba od strane protivnika izaziva određenu unaprijed poznatu reakciju.

OLAP	OLAP	OLAP	On-line analitičko procesiranje, Višedimenzionalna analiza podataka za podršku odlučivanju. Obuhvaća analizu poslovnih informacija od ad hoc upita do predviđanja, modeliranja i simulacija.
Sustavi za potporu odlučivanju	Decision Support Systems	DSS	Sustavi koji na jednostavan način vizualiziraju korporativne informacije i na taj način daju podlogu za donošenje odluka Obuhvaća OLAP, upite i izvješća
Metapodaci			Podaci o podacima
Izvlačenje, Transformacija i Transport	Extraction, Transformation, and Transportation	ETT	Pomoćni alati za kreiranje i održavanje skladišta podataka
Sustav upravljanja bazama podataka	Database Management System	DBMS	
	Data Mart		Podaci za podršku odlučivanju jedne poslovne funkcije ili jedinice

Tablica 2: Popis pojmova korištenih u sustavu poslovne inteligencije

Pojam "Business Intelligence" (BI) počeo se u hrvatskoj prevoditi kao "Poslovna inteligencija". Međutim u engleskom jeziku riječ "Intelligence"[19] ima dva značenja:

- 1.) sposobnost učenja, razumijevanja, logičkog razmišljanja, sposobnost da se te stvari rade dobro
- 2.) tajna informacija sakupljena o stranoj zemlji, osobito neprijateljskoj, osobe koje sakupljaju te informacije


U pojmu "Business Intelligence" riječ "Intelligence" ima značenje br. 2. U nastavku ću koristiti kraticu BI.

3.1. Nastanak discipline poslovne inteligencije

Poslovnu inteligenciju kao disciplinu osmislio je Stevan Dedijer sedamdesetih godina dvadesetog stoljeća, a prema njemu definicija glasi: "BI je Korištenje kolektivnog znanja organizacije sa ciljem postizanja konkurentske prednosti". Uz snažan razvoj informacijskih sustava tijekom kasnih osamdesetih godina pojavila se slijedeća definicija: BI je sposobnost organizacije da pribavi informacije, istraži ih, stekne uvid i razumijevanje što dovodi do boljeg donošenja odluka. Prema [20] pojam poslovne

inteligencije može se promatrati sa makroaspekta i mikroaspekta. S makroaspekta poslovna inteligencija je složena agregirana kategorija koja se stvara sustavnim, ali neciljanim prikupljanjem podataka o makroekonomskim kretanjima u određenoj geopolitičkoj sredini, njihovim organiziranim i strukturiranim bilježenjem, te logičkom računskom obradom radi otkrivanja trendova. U ovom radu naglasak će biti na poslovnoj inteligenciji razmatran sa mikroaspekta. Jednu od definicija poslovne inteligencije promatrane s mikroaspekta prema [21] "Poslovna inteligencija nije niti proizvod niti sustav. To je arhitektura i kolekcija integriranih operativnih aplikacija i aplikacija za potporu odlučivanju, te baza podataka koje poslovnim korisnicima omogućuju lak pristup poslovnim podacima"

Infrastruktura jednog BI sustava dana je na Slika 16 [26]



Slika 16: Infrastruktura BI sustava

Često se miješaju pojmovi poslovne inteligencije i kompetitivne inteligencije. Prema [22] BI omogućuje organizacijama da sustavno promoviraju kulturu razumijevanja i poduzimanja akcija kroz slijedeće značajke:

- Donošenje odluka bazirano na činjenicama
- Kvaliteta informacija
- Smislenost oblika informacija
- Kvantiteta informacija
- Dijeljenje informacija

3.1.1. Činjenice nasuprot mišljenjima

Povijesno gledano menadžeri su se oslanjali na intuiciju prilikom donošenja važnih poslovnih odluka. Kako se zaoštravala konkurencija, tržišta su postajala dinamičnija a resursi su postajali sve više ograničeni, instinkt i metoda pokušaja i pogrešaka više nisu efikasne metode za vođenje kompanije. Istovremeno postojale su enormne količine nedovoljno iskorištenih informacija koje su se akumulirale u raznim sustavima kao što su unos narudžbi, računovodstvo i e-mail. Vizija BI-ja promovira zaokret od spekulativnog nagađanja prema donošenju odluka baziranog na činjenicama, ljudi i informacije postaju bolje iskorišteni što dovodi do poboljšane profitabilnosti, povećanih tržišnih udjela i unaprijeđene odnose sa kupcima i korisnicima usluga.

3.1.2. Kvaliteta informacija

BI je najkorisniji ukoliko su informacije koje ga podržavaju najbolje moguće kvalitete. Kvaliteta informacija može se definirati kroz njihovu kompletnost, točnost, konzistentnost i pravovremenost. Sve dostupne i vezane informacije (interne i eksterne) moraju biti uključene kako omogućile širu perspektivu. Informacije iz razolikih izvora moraju biti sintetizirane i homogenizirane, sa zajedničkim definicijama kako bi osigurale jedinstvenu polaznu osnovu za sve korisnike. Uobičajeno je da postizanje kvalitete informacija troši većinu resursa BI sustava.

3.1.3. Smislenost oblika informacija

BI mora biti usmjeren prema korisniku tako da su informacije i analize prezentirane korisniku na način koji odražava njihovo shvaćanje vođenja poslovanja. Ne samo da mora osigurati specifične informacije ključne za njihove uloge, već to mora biti ostvareno na korisniku jednostavan način.

3.1.4. Kvantiteta informacija

Bilo je uobičajeno da se eksperti za analizu podataka posvete analiziranju internih podataka, koristeći pri tom sofisticirane alate i tehnike. BI je napravio dramatičan zaokret od specijaliziranih analitičara prema menadžerima i stručnjacima jer oni bolje shvaćaju dinamiku poslovanja. Kao integralni dio poslovnog planiranja, BI se koristi za interpretaciju povijesnih podataka, predviđanje budućih trendova kao i za određivanje i mjerenje pokazatelja poslovanja. Istraživanjem podataka iz unutarnjih i vanjskih izvora, korisnici će otkriti kretanje trendova kod klijenata i na tržištu te ih pretočiti u nove poslovne prilike i uštede.

3.1.5. Dijeljenje informacija

BI promovira aktivno dijeljenje informacija, pogleda, veza, pretpostavki, aplikacija i uvida na stanje unutar i izvan poduzeća. Dijeljenje informacija reducira redundanciju poslova, a svi korisnici profitiraju od svojih rezultata, ali i od rezultata kolega.

3.2. Informacijski sustavi kao podrška BI

Razvojem informatizacije pojedini odjeli u kompaniji počinju koristiti aplikativna rješenja pomoću kojima olakšavaju poslovanje svojih odjela. S vremenom broj takvih aplikacija raste i pojavljuju se integrirani SW paketi (npr. SAP) koji su pokrivali poslovanje svih odjela. Očekivani rezultat takvih implementacija bilo mogućnost dobivanja izvješća koja uključuju poslovne aktivnosti više raznih odjela i funkcija ili modula u tim sustavima. Ipak taj rezultat je izostao. Na Sliku 17 prikazan je primjer organizacije sa tipičnim poslovnim funkcijama i aplikacijama koje ih podržavaju. Zašto nije bilo moguće dobiti sva izvješća, unatoč tome što su podaci postojali su u bazi, a jedna aplikacija upravljala je cijelim sustavom? Naravno bilo je moguće dobiti izvješća, ali njihovo kreiranje je bilo zahtjevno, a izvođenje dugotrajno jer su takvi upiti uzimali u obzir podatke iz cijele baze.



Slika 17: Dodirne točke funkcijskih aplikacija i BI

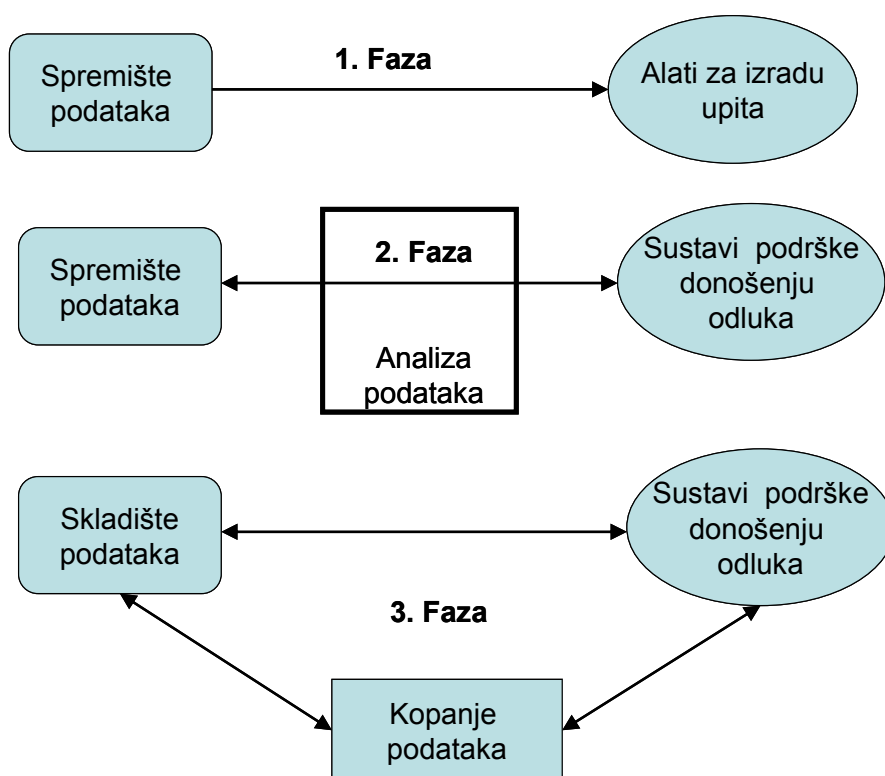
Skladišta podataka pružila su rješenje toga problema. Na Slika 18 prikazan je razvoj informacijskih sustava sa aspekta BI.

3.2.1. Prva faza upravljanja podacima

U prvoj fazi organizacije su počele primjenjivati strukturirane sustave pohrane podataka u skladu sa svojim potrebama- tipično osnovni podaci iz jednog operativnog izvora (npr. informacijski centar). U 1980-ima zadaci podrške donošenju odluka izvođeni su centralno. Provodili su ih stručnjaci analizirajući dostupne podatke. Menadžment je dobivao izvješća i grafove u papirnatom obliku.

3.2.2. Druga faza upravljanja podacima

Tržišna utakmica prisilila je organizacije na bolje upravljanje podacima, tako su usvojeni sustavi potpore odlučivanju (DSS). Stvarana su spremišta podataka iz maksimalno dva do tri izvora, a zatim bi podaci bili analizirani jednom od analitičkih tehnika. Zajedno sa razvojem spremišta podataka, razvijeni su i alati koji su koristili prednosti strukturiranosti podataka.



Slika 18: Tri faze upravljanja podacima [26]

3.2.3. Treća faza upravljanja podacima

Razvojem spremišta podataka, porastom njihova broja i nastajanjem sve većih razlika organizacije su bile prisiljene racionalizirati i unificirati podatke koristeći "Skladište podataka". Zaoštavanjem tržišne utakmice nastale su napredne tehnike analize podataka čijim korištenjem su se počele ostvarivati konkurentske prednosti. Jedan od rezultata je i ogroman porast količine podataka.

Skladište podataka pokazalo se kao ključan preduvjet BI sustava, pa zbog toga zaslužuje posebno razmatranje u poglavlju 3.3.

3.3. Skladištenje podataka

3.3.1. Definicija

Postoje razne definicije Skladištenja podataka^{XXIX}. Tako Ralph Kimball [23] smatra da je DW "kopija transakcijskih podataka posebno strukturiranih za izradu upita i analize. Larry Greenfield [24] smatra da bi prikladnija modificirana definicija glasila: "Skladište podataka je kopija transakcijskih podataka posebno strukturiranih za upite i izvještavanje", a razlozi za modificiranu definiciju su slijedeći:

- ponekad se podaci koji nisu transakcijski spremaju u DW (iako u 95-99% slučajeva to ipak jesu transakcijski podaci)
- izrada "upita i izvješća" prikladniji je izraz, zato jer su glavni "izlaz" DW-a često tablični prikazi, ili minimalno formatirana izvješća

Za razliku od ovih tehnički orijentiranih definicija svidjela mi se slijedeća koja glasi : "Skladište podataka je baza podataka skupljenih iz raznih sustava sa svrhom podrške donošenju odluka i izvještavanju"[25]. Pojednostavnjeno, kada netko kaže "Skladište podataka" obično misli na pohranjene podatke i alate koji zajedno čine moderni sustav izvještavanja.

3.3.2. Strategija kompanije kao preduvjet za DW

Prema strateškom analitičkom izvješću od Gartner Group [26] 80% DW inicijativa nisu prave DW inicijative, nego neophodna podrška fokusiranoj i specifičnoj DSS aplikaciji čija je jedina funkcija podrška određenoj poslovnoj aktivnosti neke funkcije ili poslovnog područja. Prilikom planiranja takvih DW projekata osnovni cilj nije usklađen strategijom i ciljevima organizacije. Iako povod za uvođenje DW-a može biti podrška jednoj DSS aplikaciji, započeti projekt sa takvom "strategijom" je kratkoročno razmišljanje. Prilikom samog početka projekta vizija glavnog izvršnog direktora mora biti usko povezana sa strategijom DW-a. Postoje različite vrste organizacija (npr. divizionalna nasuprot unificiranoj), i svaka od njih treba svoju specifičnu strategiju DW-a. Apsolutni imperativ prilikom postavljanja arhitekture DW-a je podrška svih dijelovima organizacije, u suprotnom će projekt propasti, a odjel za informacijske sustave će se baviti izradama specifičnih i parcijalnih DSS-ova koji će

^{XXIX} Skladištenje podataka, prijevod pojma "Data Warehousing", u nastavku će biti upotrebljavana kratica DW

podržavati taktičke ciljeve pojedinih poslovnih područja, dok ispunjavanje strateških ciljeva organizacije nikada neće doći na red.

Takvom lošem scenariju pridonose ponuđači DW sustava i BI tehnologije koji ciljaju odjel za informacijske sustave i točno određeno poslovno područje. Na taj način odgovaraju zahtjevima za što bržim rezultatima poboljšanja procesa donošenja odluka sa što je moguće nižim troškovima. Zato se i cijena implementacije takvih sustava uglavnom kreće od 200.000 do milijun dolara. Naravno da su moguće i puno viši iznosi ukoliko se radi o mega tvrtki.

Korisnici željni informacija učestalo traže od menadžera poslovnih područja financiranje i implementaciju aplikacije. Zbog takvih zahtjeva i tehnologija koje su u ponudi, menadžeri poslovnih jedinica često odobre kupnju hardware-a i software-a kako bi uspostavili vlastiti BI sustav. To se obično izvodi na dva načina: Odjel za informacijske sustave isključen je iz procesa implementacije, ili je prisiljen kreirati rješenja koja će opsluživati samo interese pojedinog poslovnog područja ili funkcije, dok će potrebe organizacije kao cjeline biti zanemarene.

Kada je odjel za informacijske sustave isključen iz implementacije, novi sustav ne dijeli podatke sa postojećim aplikacijama. Nakon završetka implementacije "poslovna područja" često otkriju kako nemaju dovoljno ljudi i znanja podršku i održavanje sustava. To se obično rješava na jedan od tri načina:

- Podrška sustavu prepušta se vanjskim izvođačima
- Stvara se mali vlastiti odjel za informacijske sustave
- Postojeći odjel za informacijske sustave mora preuzeti brigu o sustavu.

Svaki od ova tri scenarija otprilike red veličine više od centralno projektiranog i strukturiranog sustava.


Slijedeća "metoda implementacije" (osim isključivanja) je natjerati odjel za informacijske sustave da implementira sustav u kratkom vremenu nedostatnom za usklađivanje DW-a sa strategijom organizacije. Na taj način zahtjevi koje su postavili korisnici iz dotičnog poslovnog područja su ispunjeni, ali takav sustav prilagođen isključivo za jednom poslovnom području/funkciji nije pravi sustav podrške donošenju odluka.

Odjel za informacijske sustave mora imati aktivnu ulogu u implementaciji arhitekture DW-a. To se posebno odnosi na brigu o tome da svi relevantni sustavi budu integrirani, te da se osigura kvaliteta podataka. Odjel za informacijske sustave mora zastupati takvu perspektivu DW-a koja obuhvaća cijelu organizaciju, što znači da

moraju biti uključeni podaci iz svih udaljenih podružnica i kompanija kćeri. Takva sveobuhvatna implementacija DW-a dovest će do unaprijeđenih poslovnih procesa, a kroz analizu podataka mogu nastati nove poslovne prilike.

3.3.3. Arhitektura DW sustava

Tipičan DW sustav prikazan je na Slika 19.



Slika 19: Arhitektura DW sustava

Tipična arhitektura DW sustava sadrži alate za slijedeće aktivnosti:

- ekstrakciju podataka iz više raznih operativnih baza podataka kao i vanjskih izvora
- čišćenje, transformaciju i integriranje
- za učitavanje podataka u skladište podataka
- povremeno ažuriranje skladišta, kako bi se zahvatile promjene nastale u izvorima
- čišćenje podataka u skladištu

Osim glavnog skladišta podataka postoje i specijalizirani "Data Mart" za pojedine odjele. Podaci iz skladišta i "Data Martova" pohranjeni su na jednom ili više

skladišnih servera koji njima upravljaju, te omogućuju višedimenzionalni pogled brojnim korisničkim alatima (za izradu upita, za pisanje izvješća, analizu i dubinsku analizu). Još postoji spremište za pohranu i upravljanje metapodacima, kao i alati za nadzor i upravljanje cijelog DW sustava.

3.3.4. Razlike između Operativnih baze podataka i DW-a

Vrlo lako se uočava da su operativne baze razdvojene od DW-a.

Za to postoji više razloga. DW podržava OLAP (On-line analitičko procesiranje) čija se funkcionalnost značajno razlikuje od OLTP (On-line transakcijsko procesiranje) koje po tradiciji podržava operativne baze podataka.

Tipična funkcija OLTP aplikacija je automatiziranje procesuiranja "birokratskih" zadataka kao što je unos narudžbi i bankarske transakcije. Takvi zadaci su strukturirani i repetitivni i sastoje se od kratkih izoliranih transakcija. Takve transakcije zahtijevaju detaljne i aktualne podatke te čitanje i ažuriranje nekoliko (desetina) podataka kojima se pristupa prvenstveno preko njihovog primarnog ključa.

Operativne baze podataka znaju imati stotine megabajta ili čak gigabajta. Konzistentnost i obnovljivost takvih baza je kritična, a glavna mjera uspješnosti je maksimizacija broja transakcija.

Nasuprot operativnih baza podataka, DW-i su namijenjeni potpori donošenja odluka. Povijesno gledano sažeti i konsolidirani podaci važniji su od detaljnih pojedinačnih zapisa. Pošto DW sadrži konsolidirane podatke iz nekoliko operativnih baza podataka kroz dugo vremensko razdoblje one su za red veličine veće od operativnih baza (stotine gigabajta do nekoliko terabajta). Njihovo radno opterećenje čine mnogobrojni kompleksni ad hoc upiti koji izvode mnoga pretraživanja, pridruživanja i spajanja. Broj upita i brzina odabira važniji su parametar za procjenjivanje uspješnosti od broja transakcija.

3.3.5. Faze uvođenja DW-a

Dizajn implementacija DW-a je izuzetno kompleksan proces, a sastoji se od slijedećih aktivnosti:

- Definiranje arhitekture, planiranje kapaciteta i odabir skladišnih servera, baza podataka, OLAP servera i alata

- Integriranje servera, pohrane podataka i korisničkih alata
- Projektiranje sheme skladišta
- Definiranje fizičke organizacije skladišta, smještaja podataka, particioniranje, i metoda pristupa
- Povezivanje sa izvorima podataka preko uređaja za povezivanje (gateway) i ODBC drivera
- Izrada skripti za izvlačenje, čišćenje, transformaciju, učitavanje i ažuriranje podataka
- Punjenje spremišta metapodataka sa shemama, definicijama pregleda, skriptama i ostalim metapodacima
- Izrada i implementacija korisničkih aplikacija
- Širenje dostupnosti skladišta i aplikacija na sve korisnike

3.3.6. Pozadinski alati i programi

Sustavi DW-a koriste mnogobrojne alate za ekstrakciju i čišćenje podataka, kao i pomoćnih programa za učitavanje i ažuriranje podataka u skladištu. Ekstrakcija podataka iz vanjskih izvora obično se provodi preko standardnih međusklopova (EDA/ SQL, ODBC, Oracle Open Connect, Informix Enterprise Gateway).

3.3.6.1 Pročišćavanje podataka

Skladište podataka koristi kod donošenja odluka, stoga je izuzetno bitno da podaci budu točni. Pošto se radi o ogromnim količinama podataka iz raznih izvora, postoji velika vjerojatnost grešaka i nekonzistentnosti podataka. Zbog toga se alati za detekciju nekonzistentnosti mogu itekako isplatiti. Neki primjeri gdje je neophodno pročišćavanje podataka su: nekonzistentne dužine polja, nekonzistentni opisi, vrijednosti, prazna polja i narušen integritet veza između podataka. Naravno, polja koja su na obrascima za unos podataka opcionalna uvijek su puna netočnosti. Postoje tri klase alata za pročišćavanje podataka:

- Alati za migraciju podataka-moguće je definirati jednostavna pravila za transformaciju npr. "zamijeni riječ *Hrvatski telekom* sa T-Com"

- Alati za "pranje" podataka- koriste specifična znanja (npr. imena mjesta). Često koriste i programe za provjeru gramatike i pomoću fuzzy logike izvode pročišćavanja podataka iz različitih izvora
- Auditiranje^{xxx} podataka omogućuje otkrivanje pravila i veza (ili signalizira slučajeve kada su prekršena) detaljnim skeniranjem podataka

Neki autori ove alate smatraju dijelom varijantama "Data Mining-a".

3.3.6.2 Učitavanje podataka

Nakon ekstrakcije, čišćenja i transformiranja podaci se moraju učitati u skladište. Mogući su još zahtjevi za dodatnim procesuiranjem (npr. provjera integriteta veza, sortiranje, sažimanje, spajanje i ostale radnje kojima bi se gradile tablice spremjene u skladištu. Korisnički programi za punjenje skladišta moraju dopuštati administratoru praćenje statusa, prekidanje i ponovno startanje nakon ispravljanja pogreške. Korisnički programi za učitavanje podataka u skladište rade sa daleko većim količinama podataka od operativnih baza podataka. Postoji izuzetno kratki vremenski interval (obično preko noći) kada se skladište može isključiti (off-line) kako bi se ažuriralo. Sekvencijalno učitavanje može potrajati jako dugo (učitavanje terabajta podataka može trajati danima, pa čak i tjednima). Zbog toga se pribjegava paralelizmu u učitavanju podataka. Ipak usprkos paralelizmu proces je dugačak i njegovo upravljanje postaje sve teže.

3.3.6.3 Ažuriranje podataka

Ažuriranje skladišta podataka podrazumijeva usklađivanje podataka u izvoru sa podacima u skladištu koji su derivirani. Kod ažuriranja podataka postavljaju se dva glavna pitanja:

- Kada ažurirati?
- Kako ažurirati?

Uobičajena praksa je da skladište ažuriramo periodički (npr. jednom dnevno ili jednom tjedno). Postoje izuzetni slučajevi kod nekih OLAP upita koji trebaju trenutne podatke (npr. stanje zaliha točno u minuti). Politiku ažuriranja određuje sistem administrator ovisno o potrebama korisnika i prometu, a može razlikovati ovisno o


^{xxx} Audit (eng)-Službeno ispitivanje poslovnih ili finansijskih podataka kako bi se provjerila njihova točnost

izvoru. Tehnike ažuriranja mogu ovisiti o značajkama izvora podataka i mogućnostima servera. Ekstrakcija cijelog izvora podataka je obično preskupa, ali ponekad kada se radi o nekim pravnim pitanjima jedino moguće rješenje. Većina današnjih baza podataka ima replike servera. Tako se podaci ažuriraju na jednom mjestu a zatim se repliciraju na druge servere.

3.3.7. Konceptualni model i korisnički alati

3.3.7.1 Konceptualni model

Popularan konceptualni model koji utječe na korisničke alate, strukturu baze i generatore upita za OLAP je višedimenzionalni pogled na podatke u skladištu. U višedimenzionalnom modelu podataka postoji skup brojčanih pokazatelja koji su predmet analize (primjeri prodaja, budžet, prihodi, inventar, ROI). Svaki od tih pokazatelja ovisi o skupu dimenzija koje osiguravaju sadržaj za mjeru. Na primjer, dimenzije pridružene sa iznosom prodaje mogu biti grad, ime proizvoda, i datum prodaje. Pretpostavka je da dimenzije jednoznačno definiraju pokazatelj. U tom slučaju višedimenzionalni podaci definiraju pokazatelj kao vrijednost u višedimenzionalnom prostoru sa zadanim dimenzijama (koordinatama). Svaka dimenzija opisana je skupom atributa. Na primjer dimenzija "Proizvod" može se sastojati od četiri atributa: kategorije, proizvodne grane, godine proizvodnje i prosječnog profita.



Slika 20: Prikaz modela višedimenzionalnih podataka

Atributi dimenzija mogu biti povezani kroz hijerarhijske odnose. U Slika 20 proizvod je vezan sa kategorijom i industrijom kroz hijerarhijske veze.

Slijedeća odlika višedimenzionalnog konceptualnog modela za OLAP je posebna važnost koju pridaje pridruživanju pokazatelja jedne ili više dimenzija kao jednoj od ključnih operacija. Tako npr. možemo dobiti podatke o ukupnoj prodaji u cijeloj državi po godinama. Često je korištena i međusobna usporedba dva indikatora (npr. prodaja i budžet). Vrijeme je dimenzija koja ima posebnu važnost u sustavu donošenja odluka (npr. analiza trendova).

3.3.7.2 Korisnički alati

Višedimenzionalni model podataka izrastao je iz popularnih tabličnih kalkulatora često korištenih od strane poslovnih analitičara (Ms Excel). Tablični kalkulatori su još uvijek najpoželjnije sučelje za OLAP. Izazov koji se stavlja pred OLAP je podržavanje upita na izuzetno velikim tablicama (nekoliko GB).

Jedna od najpopularnijih operacija koju podržavaju višedimenzionalni tablični kalkulatori je pivotiranje. Razmotrimo slučaj prikazan u Slika 20 gdje svaki red predstavlja prodaju. Pretpostavimo da imamo po jednu kolonu za svaku dimenziju i još jednu kolonu koja predstavlja iznos prodaje. Najjednostavniji način pivotiranja je da odaberemo dvije dimenzije koje ćemo upotrijebiti za stvaranje pokazatelja (u ovom slučaju prodaje). Vrijednosti novonastalog pokazatelja često su prikazane u tablici (koordinatnom sustavu) gdje svaka vrijednost (x,y) odgovara vrijednosti novonastalog pokazatelja kada prva dimenzija ima vrijednost x, a druga dimenzija ima vrijednost y. Tako u ovom slučaju ako su odabrane vrijednosti grad i godina, tada će na x osi biti gradovi, a na y osi godine. Točka (x,y) predstavljat će prodaju za grad x godini y. To znači da vrijednosti iz početne tablice prelaze u zaglavlja redaka odnosno stupaca nove tablice.

Pivotiranje pruža mogućnost raznih kombinacija dimenzija, dodatnih skupljanja uzlazno po hijerarhiji, kao i propadanja do nižih nivoa, pa do sortiranja i grupiranja.

Iako su višedimenzionalne tablice privukle veliki interes jer pružaju krajnjim korisnicima mogućnost analiziranja poslovnih podataka, još uvijek nisu potisnule tradicionalnu metodu analize pomoću okruženja upravljanog upitima. Takvo okruženje kao analitički alat koristi pohranjene procedure i prethodno definirane kompleksne upite. Dotične aplikacije često koriste alate za pristup "sirovim"

podacima a pristup je optimiran s obzirom na server. Često se koristi Ms Access za kreiranje SQL upita jednostavnim klikanjem i povlačenjem.

I na kraju je potrebno naglasiti da postoji velika grupa alata za dubinske analize koji se koriste kao sučelje kojim krajnji korisnici pristupaju podacima u skladištu.

3.3.8. Metapodaci i upravljanje DW-om

Kako skladište podataka odražava poslovni model jedne organizacije ključni element arhitekture skladišta je upravljanje metapodacima. Postoji više vrsta metapodataka kojima je potrebno upravljati.

Administrativni metapodaci uključuju sve informacije neophodne za uspostavu i korištenje skladišta, opisi izvornih baza podataka, krajnji korisnički alati, definicija sheme skladišta, derivirani podaci, dimenzije i hijerarhije, predefinirani upiti i izvješća, smještaj i sadržaj Data Martova, fizička organizacija podataka, ekstrakcija podataka, čišćenje, pravila transformacije, politike ažuriranja i čišćenja, profili korisnika, autorizacije i kontrola nivoa pristupa.

Poslovni metapodaci uključuju poslovne termine i definicije te vlasništvo nad podacima.

Operativni metapodaci uključuju informacije koje se sakupljaju tijekom rada skladišta: odnos transformiranih i migriranih podataka, aktualnost podataka (aktivno, arhivirano ili obrisano) i nadzorne informacije kao što su statistika korištenja, izvješća o greškama i inspekcijama.

Spremišta matapodataka često se koriste za pohranu i upravljanje svih metapodataka vezanih uz skladište. Spremište omogućuje dostupnost metapodataka alatima i procesima za dizajn, postavljanje, korištenje i administriranje skladišta.

Stvaranje sustava skladištenja, kao i upravljanje tim sustavom izuzetno je zahtjevno. Postoji mnogo različitih klasa alata koje su u stanju opsluživati različite aspekte procesa uspostavljanja sustava.

Alate za razvoj koristimo kako bi kreirali i mijenjali sheme, poglede, skripte, veze, upite i izvješća.

Alati za planiranje i analizu koje koristimo u "Što ako"^{XXXI} scenarijima kao što su razumijevanje utjecaja promjena u shemi na brzinu ažuriranja podataka ili na planiranje kapaciteta.

Alati za upravljanje skladištem koriste se za nadzor skladišta, statistiku izvještavanja, te prijedloge administratoru (npr. korištenje particija i sumarnih tablica, trajanje izvođenja upita, izvješća o tome koje grupe korisnika su tražile koje podatke, vršno i prosječno radno opterećenje kroz vrijeme, izvještavanje o izvanrednim situacijama i ostali pokazatelji kvalitete rada sustava.

3.4. Dubinske analize (Data mining)

DM je izuzetno raširen alat, ali u većini slučajeva nije optimalno korišten. Ključan nedostatak DM-a je nemogućnost automatske kategorizacije, analize slika i velikih nestrukturiranih tekstualnih baza. Ključna vrijednost DM-a je "otkrivanje" novih stvari. Organizacije koje su godinama pratile i analizirale svoje podatke primjenom DM-a otkrile su veze i odnose koji prije nisu bili uočljivi i na taj način stekle prednost u kompetitivnom okruženju.

Osim vrlo dosljednog poštivanja metodologije prije implementacije DM-a, neophodno je na samom početku postaviti poslovne ciljeve koji se očekuju od DM-a. Takav postavljeni cilj usmjerava proces i pomaže prilikom donošenja odluka u pojedinim ključnim fazama procesa DM-a.

Ovisno o industriji ili odjelu koji je inicirao uvođenje DM-a ciljevi mogu varirati od identifikacije najvrednijih klijenata, zadržavanja dobrih klijenata, produktivnosti proizvodne opreme, identifikacije potrebe promotivnih kampanja, optimizacije kargo tereta, ili čak potrage za kriminalcima. Bez obzira o kojoj vrsti cilja se radi, jednom kada ga postavimo treba ga održavati tijekom cijelog procesa DM-a.

3.4.1. DM aplikacije

DM je proces otkrivanja smislenih novih veza, uzoraka i trendova "prosijavanjem" ogromnih količina podataka spremljenih u skladištima, koristeći tehnologiju prepoznavanja uzorka te statističke i matematičke tehnike.

Tri su glavna razloga koja motiviraju poduzeća na uvođenje DM-a.

^{XXXI} Što ako-What if (eng.)

- **Vizualizacija podataka.** Analitičari moraju učiniti smislenima ogromne količine informacija pohranjene u bazama. Prije bilo kakve analize humanizirati podatke s kojima rade i pronaći pametan način njihovog prikaza.
- **Otkrivanje znanja.** Cilj otkrivanja znanja je utvrđivanje skrivenih veza, uzoraka ili odnosa između podataka pohranjenih u bazi.
- **Ispravljanje podataka.** Kod konsolidacije ogromnih baza podataka, često se dogodi da podaci nisu kompletni, te da čak postoje kontradiktorne informacije. Slijedi krpanje rupa na najkonzistentniji mogući način.

3.4.2. Prepreke DM-u

Pored tehničkih barijera koje otežavaju DM projekte postoje i ne-tehničke. Jedna od njih je nedovoljan broj kvalificiranih analitičara i statističara koji mogu interpretirati ogromne količine informacija. Zato je prilikom razvoja rješenja neophodno primjenjivati metodologiju čiji su glavni koraci [27]:

- Odabir i priprema baze podataka
- Analiza klastera i značajki
- Odabir alata
- Hipoteza za testiranje otkrivanja znanja
- Primjena znanja

3.4.2.1 Odabir i priprema baze podataka

Prvi korak uključuje identifikaciju baza podataka i faktora koje treba istražiti. Ukoliko je moguće potrebno je kreirati on-line rječnike podataka iz kojih traženi zapisi mogu biti povučeni u jednostavne datoteke kakve se koriste u većini analiza. Nipošto ne treba podcijeniti ovaj korak jer interesantne baze podataka može održavati više odjela koristeći različite operativne sustave, HW i lokacije. Moguće je da baza podataka nije unutar poduzeća (npr. demografski podaci koje obično kupuje marketing).

Priprema podataka uključuje popunjavanje vrijednosti koje nedostaju i ispravljanje grešaka.

3.4.2.2 Analiza klastera i značajki

Velike grupe podataka nastale u pripremnoj fazi dijele se korištenjem tehnika klasteriranja. Slijedeća je malo detaljnija, ali još uvijek dosta gruba analiza značajki kako bi se odredilo koji čimbenici imaju najznačajniji doprinos formiranju klastera, te koji čimbenici su ključni za postizanje određenih ciljeva. Analiza klastera i značajki može svesti problem na manji broj faktora. Ovaj proces je uvijek stvar kompromisa jer ponekad neki naizgled beznačajan faktor može imati važan utjecaj na ostale.

3.4.2.3 Odabir alata

Danas na raspolaganju imamo veliki broj alata, a da bi napravili dobar izbor služe nam slijedeća pitanja:

- Koliko primjera se može obrađivati istovremeno?
- Kolika je potreba za prethodnom doradom podataka?
- Mogu li korisnici izraziti i testirati hipotezu ?
- Sadrže li izlazni podaci veze, modele, drva odluke ili brojeve?
- Da li je moguće jednostavno ažurirati model novim informacijama?
- Koliko je napora i stručnosti potrebno za korištenje razmatrane tehnologije?

3.4.2.4 Testiranje hipoteze i otkrivanje znanja

Ovaj korak se najčešće poistovjećuje sa pojmom DM-a. Tijekom procesa formiraju se i testiraju hipoteze (odozgo prema dolje)^{xxxii}, otkrivaju se nove veze (odozdo prema gore)^{xxxiii} i te se radi "što-ako"^{xxxiv} analiza. Bez obzira u kojem smjeru se odvija proces mogu nastati mnogi problemi u fazi testiranja i otkrivanja. Veličina uzorka, procesno vrijeme, kompleksnost podataka samo su neki utjecajni čimbenici koje treba razmatrati. Izlazni rezultat procesa DM-a ovisi o primijenjenom proizvodu i tehnologiji, a često se nalazi u obliku veza, korelacija, modela predviđanja i grafova međusobnih odnosa.

xxxii top down
xxxiii bottom -up
xxxiv What if

3.4.2.5 Primjena znanja

U većini slučajeva veze proizašle iz procesa otkrivanja mogu se direktno dodati u kod procedura, ili ukoliko je broj veza velik a relativno ih jednostavno ažurirati – u sustav baziran na znanju. Modele predviđanja često je moguće integrirati direktno u kod aplikacije, posebno u slučajevima kada se radi o proizvodima čiji izlazni modeli su u uobičajenim jezicima kao što je "C". Kako je DM iterativan proces, otkriveno znanje može se vratiti u proces kako bi došlo do novih otkrića.

3.4.3. Tehnike koje koristi DM

Prilikom DM-a moguće je primijeniti veliki broj tehnika na različite funkcije. Najpopularnije su vizualizacija, statistika, indukcija i neuronske mreže. Većina ovih tehnika dosegla je svoju zrelost, ali njihovu primjenu treba provoditi s određenom dozom opreza.

3.4.3.1 Vizualizacija

Vizualizacija se oslanja na ljudski aspekt analize. Čak i najbolji skupovi veza ili tablica podataka mogu otkriti više informacija ukoliko ih istaknemo bojama, teksturama ili 2D ili 3D prikazom sa animacijama. Tehnike vizualizacije mogu se koristiti tijekom procesa istraživanja informacija, a posebno su korisne u početnim fazama grupiranja. Vizualizacija se može koristiti u kombinaciji sa drugim tehnikama (npr. indukcijom). Nedostatak vizualizacije je teškoća prikaza veza koje sadrže više od četiri varijable. Dodatna poteškoća je prikazivanje vremena čak i korištenjem više grafova i animacija.

3.4.3.2 Statistika

Statistika je najčešće korištena tehnika u DM problemima. Statistiku koriste istraživači koji preferiraju tradicionalne metode, kao i oni koji koriste napredne metode kako izvršili brojne funkcije kao što su klasteriranje, analiza čimbenika i predviđanja. Često se koristi zajedno sa drugim tehnikama i obično je prvi izbor za početnu analizu prilikom identifikacije predvidivih faktora. Stalno se razvijaju nove statističke tehnike, te se može reći kako statistika ipak ima glavnu riječ u analizi podataka. Nedostatak statistike je u tome što je često neophodno davati pretpostavke, što je za osobe koje nisu statističari teško provedivo. Dodatne poteškoće nastaju ukoliko imamo veliki broj varijabli koje još k tome nisu linearne.

3.4.3.3 Indukcija

Indukcija je proces kojim logičnim razmišljanjem od činjenica dolazimo do hipoteze. Suprotno od indukcije je dedukcija kada polazimo od hipoteze i pokušavamo ju dokazati koristeći činjenice. Činjenice u procesu DM-a su zapisi u bazama podataka, a hipoteza je uobičajeno drvo odluke koje pokušava grupirati podatke na smislen način.

3.4.3.4 Strojno učenje

Strojno učenje izuzetno je značajno, stoga zaslužuje posebno poglavlje (vidi poglavlje 3.5)

3.5. Strojno učenje i mreže povjerenja

3.5.1. Što je strojno učenje?

Učenje kao i inteligencija pokriva tako široku paletu procesa da ga je teško precizno definirati. Definicije u rječnicima uglavnom su opće fraze i glase: "steći znanje, ili razumijevanje nečega, postati vješt u, proučavanjem, instruiranjem ili iskustvom". Mnoge tehnike u strojnom učenju potekle su od napora psihologa u preciznijem pojašnjavanju teorija procesa učenja kod ljudi i životinja upotrebom računalnih modela.

Prema Nils J. Nilsson-u [28] (*Stanford, Artificial Intelligence Laboratory*) definicija strojnoga učenja glasi: "Strojevi uče kada god mijenjaju svoju strukturu, program ili podatke temeljem vlastitih inputa ili kao odgovor na informaciju iz okoline".

3.5.2. Kako se strojno učenje primjenjuje u Data Miningu?

Baze podataka bogate su skrivenim informacijama koje se mogu koristiti za donošenje inteligentnih poslovnih odluka. Metodama klasifikacije mogu se ekstrahirati modeli koji opisuju važne klase podataka ili predviđaju buduće trendove. Najčešće korištene tehnike klasifikacije strojnim učenjem su:

- Bayesova klasifikacija i Bayesove mreže povjerenja
- Neuronske mreže
- Indukcijsko drvo odluke

3.5.2.1 Klasifikacija podataka

Klasifikacija podataka je proces koji se sastoji od dva koraka. U prvom koraku gradi se model, opisujući unaprijed određeni skup klasa podataka ili koncepte. Model se gradi analizom atributa koji opisuju objekte iz baze podataka. Za svaki objekt pretpostavlja se pripadnost unaprijed definiranoj klasi, što je ustvari određeno jednim od atributa koji se naziva "atribut oznake klase"^{xxxv}. Objekti koje analiziramo kako bi izgradili model nazivaju se "skup podataka za trening"^{xxxvi}. Pojedini objekti iz skupa za trening tj. "uzorci za trening"^{xxxvii} dobivaju se slučajnim odabirom. Kako postoji oznaka klase za svaki uzorak za trening, ovaj korak se naziva i "učenje pod nadzorom"^{xxxviii} (učenje modela nadzire se tako što je određeno u koju klasu pripada pojedini uzorak za trening). Naučeni model ustvari je niz klasifikacijskih pravila, drva odluke ili matematičkih formula. Na primjer, iz baze podataka o korisničkim kreditima mogu se naučiti pravila klasifikacije koja bi identificirala klijente sa dobrim ili lošim kreditnim rejtingom. Pravila klasifikacije možemo koristiti kako bi klasificirali buduće uzorke ili nam mogu poslužiti za bolje razumijevanje baze podataka.

U drugim koraku model se koristi za klasifikaciju. Prvo se procjenjuje predvidiva točnost modela (ili klasifikator). Postoji nekoliko metoda za provjeru točnosti klasifikatora. Metoda izdržljivosti^{xxxix} jednostavna je tehnika koja koristi pokusni skup uzoraka označenih klasa. Uzorkovanje je nasumično i neovisno o uzorcima za trening. Točnost modela za zadani test je ustvari postotak točno klasificiranih uzoraka iz testnog skupa. Za svaki testni uzorak poznata oznaka uspoređuje se sa naučenom koju je dao model. Ukoliko bi točnost procjenjivali na uzorcima za trening na kojima se gradio model, procijenjena točnost bila bi preoptimistična, zato jer se svaki model nastoji u potpunosti uskladiti sa podacima, tako da u model mogu biti uključene anomalije karakteristične samo skupu podataka za trening. Zato koristimo posebni skup za testiranje.

Ako je točnost modela prihvatljiva možemo ga koristiti za klasifikaciju budućih skupova podataka.

^{xxxv} Atribut oznake klase-Class Label Attribute

^{xxxvi} Skup podataka za trening-Training Data Set

^{xxxvii} Uzorci za trening-Training Samples

^{xxxviii} Učenje pod nadzorom-Supervised Learning

^{xxxix} Metoda izdržljivosti-Holdout Method

3.5.2.2 Kriteriji za usporedbu klasifikacijskih metoda

Klasifikacijske metode moguće je uspoređivati i procjenjivati prema slijedećim kriterijima:

- **Predvidiva točnost:** Sposobnost modela da ispravno predvidi oznaku klase novih ili od modela neviđenih podataka
- **Brzina:** Troškovi procesorskog vremena potrebnog za generiranje i korištenje modela
- **Robusnost:** Sposobnost modela da donese ispravnu odluku u slučajevima šumova u podacima ili nedostajućih vrijednosti
- **Skalabilnost:** Sposobnost efikasne konstrukcije modela za velike brojeve podataka
- **Mogućnost interpretacije:** Nivo mogućnosti uvida i razumijevanja koje model može omogućiti

3.5.3. Bayesova klasifikacija

Bayesovom klasifikacijom predviđa se vjerojatnost da će odabrani uzorak pripadati točno određenoj klasi. Bayesovi klasifikatori su statistički klasifikatori, bazirani su na Bayesovom teoremu. Studije koje su se bavile usporedbom algoritama za klasifikaciju ustanovile su da je prosti Bayesov klasifikator poznat kao "naivni Bayesov klasifikator"^{XL} po učinku usporediv sa drvom odluke i neuronskim mrežama. Prednost Bayesovih klasifikatora pokazala se u njihovoj brzini i točnosti kod primjene na velikim bazama podataka.

Naivni Bayesov klasifikator polazi od pretpostavke je vrijednost jednog od atributa u nekoj klasi neovisna o vrijednostima ostalih atributa. Ta pretpostavka naziva se "klasom uvjetovana neovisnost"^{XLl}. Njezina svrha je smanjenje broja računskih operacija te se stoga smatra "naivnom".

3.5.3.1 Bayesov teorem

Neka je **X** uzorak podataka nepoznate oznake klase. Neka je **H** hipoteza da uzorak podataka **X** pripada klasi **C**. Za probleme klasifikacije želimo odrediti $P(H|X)$

^{XL} Naivni Bayesov klasifikator-Naive Bayesian Classifier

^{XLl} Klasom uvjetovana neovisnost- Class Conditional Independence

vjerojatnost točnosti hipoteze **H** na uzorku **X**. $P(\mathbf{H}|\mathbf{X})$ je vjerojatnost nakon događaja ili *aposteriori* vjerojatnost od **H** uvjetovana na **X**.

Na primjeru bi to izgledalo ovako:

*Pretpostavimo da su podaci iz svijeta voća, a svaki od njih je opisan bojom i oblikom. Neka je **X** crveno i okruglo a **H** hipoteza da je **X** jabuka. U tom slučaju $P(\mathbf{H}|\mathbf{X})$ predstavlja naše povjerenje da je **X** jabuka, zato jer smo vidjeli da je crvena i okrugla. Nasuprot tome $P(\mathbf{H})$ je vjerojatnost prije događaja ili *apriori* vjerojatnost od **H**. U ovom slučaju to je vjerojatnost da će bilo koji uzorak biti jabuka bez obzira na boju i oblik.*

Aposteriori vjerojatnost $P(\mathbf{H}|\mathbf{X})$ temelji se na više informacija nego apriori vjerojatnost $P(\mathbf{H})$. Slično tome $P(\mathbf{X}|\mathbf{H})$ je aposteriori vjerojatnost od **X** uvjetovana **H**. U navedenom primjeru to bi značilo vjerojatnost da **X** crveno i okruglo s obzirom na to poznatu činjenicu da se radi o jabuci. $P(\mathbf{X})$ je apriori vjerojatnost od **X** ili vjerojatnost da je bilo koji od uzoraka crven i okrugao.

Kako se procjenjuju te vjerojatnosti? $P(\mathbf{X})$, $P(\mathbf{H})$, $P(\mathbf{X}|\mathbf{H})$ mogu se procijeniti na temelju danih podataka. Bayesov teorem omogućava izračun aposteriori vjerojatnosti $P(\mathbf{H}|\mathbf{X})$ na temelju $P(\mathbf{X})$, $P(\mathbf{H})$, $P(\mathbf{X}|\mathbf{H})$ i glasi:

$$P(\mathbf{H} | \mathbf{X}) = \frac{P(\mathbf{X} | \mathbf{H}) \cdot P(\mathbf{H})}{P(\mathbf{X})}$$

3.5.3.2 Postupak naivne Bayesove klasifikacije

Naivna Bayesova klasifikacija, ili prosta Bayesova klasifikacija radi na slijedećem principu:

- 1) Svaki uzorak podataka predstavljen je n -dimenzionalnim vektorom $\mathbf{X}=(x_1, x_2, \dots, x_n)$ koji opisuje n mjerenja uzorka to jest n atributa A_1, A_2, \dots, A_n .
- 2) Pretpostavimo da postoji m klasa, C_1, C_2, \dots, C_m . Za nepoznati uzorak podataka \mathbf{X} (uzorak koji nema određenu klasu) klasifikator će predvidjeti da \mathbf{X} pripada klasi za koju ima najveću aposteriori vjerojatnost uvjetovanu na \mathbf{X} , to jest naivni Bayesov klasifikator dodjeljuje nepoznati uzorak \mathbf{X} klasi C_i ako i samo ako je:

$$P(C_i | \mathbf{X}) > P(C_j | \mathbf{X}) \text{ za } 1 \leq j \leq m, j \neq i$$

Na taj način maksimiramo $P(C_i | \mathbf{X})$. Klasa C_i za koju je $P(C_i | \mathbf{X})$ maksimalan je maksimalna aposteriori hipoteza. Prema Bayesovom teoremu je

$$P(C_i | X) = \frac{P(X | C_i) \cdot P(C_i)}{P(X)}$$

- 3) Pošto je $P(X)$ konstantan za sve klase potrebno je maksimirati samo $P(X | C_i) \cdot P(C_i)$. Ukoliko apriori vjerojatnosti klasa nisu poznate, uobičajena je pretpostavka da su vjerojatnosti jednake tj. da je $P(C_1)=P(C_2)=\dots=P(C_m)$ i prema tome maksimiramo samo $P(X | C_i)$. Ukoliko vjerojatnosti nisu jednake, ostajemo kod izraza $P(X | C_i) \cdot P(C_i)$. U tom slučaju apriori vjerojatnosti mogu se procijeniti izrazom:

$$P(C_i) = \frac{s_i}{s}$$

gdje su:

s_i -broj uzoraka za trening u klasi C_i

s -ukupan broj uzoraka za trening

- 4) Skupovi podataka imaju mnogo atributa pa bi sa aspekta procesorskog vremena bilo izrazito skupo izračunavati $P(X|C_i)$. Kako bi smanjili broj računskih operacija prilikom izračuna $P(X|C_i)$ uvodi se pretpostavka "klasom uvjetovane neovisnosti". Njome se pretpostavlja da su vrijednosti atributa međusobno neovisne unutar klase uzorka, ili pojednostavnjeno, ne postoje međusobne veze i ovisnosti između atributa. Tako je

$$P(X | C_i) = \prod_{k=1}^n P(x_k | C_i)$$

Vjerojatnosti $P(x_1|C_i)$, $P(x_2|C_i)$,..., $P(x_n|C_i)$ mogu se procijeniti iz uzorka za trening tako da vrijedi:

- i. Ako je A_k kategorijalna, onda je $P(x_k | C_i) = \frac{s_{ik}}{s_i}$, gdje je

s_{ik} –broj uzoraka za trening koji pripadaju klasi C_i , a vrijednost atributa A_k je x_k

s_i - broj uzoraka koji pripadaju klasi C_i

- ii. Ako je A_k kontinuirana vrijednost, najčešće se pretpostavlja da vrijednosti atributa podliježu zakonitostima Gaussove razdiobe, tako da je:

$$P(x_k | C_i) = g(x_k, \mu_{C_i}, \sigma_{C_i}) = \frac{1}{\sqrt{2\pi}\sigma_{C_i}} e^{-\frac{(x_k - \mu_{C_i})^2}{2\sigma_{C_i}^2}}$$

gdje je:

$g(x_k, \mu_{C_i}, \sigma_{C_i})$ -gaussova normalna funkcija gustoće za atribut A_k

μ_{C_i}, σ_{C_i} -aritmetička sredina i standardna devijacija za vrijednosti atributa

A_k iz uzoraka za trening, a koji pripadaju klasi C_i

- 5) Da bi klasificirali nepoznati uzorak X , $P(X | C_i) \cdot P(C_i)$ izračunava se za svaku klasu C_i . Uzorak X dodjeljuje se klasi C_i ako i samo ako je

$$P(X | C_i) \cdot P(C_i) > P(X | C_j) \cdot P(C_j) \quad \text{za } 1 \leq j \leq m, j \neq i$$

što ustvari znači da se klasi C_i dodjeljuju oni uzorci za koje je $P(X|C_i)P(C_i)$ maksimalan.

3.5.3.3 Koliko su efikasni Bayesovi klasifikatori?

U teoriji Bayesovi klasifikatori imaju minimalan postotak pogreške u usporedbi sa ostalim klasifikatorima. U praksi to nije uvijek slučaj zbog netočnosti u pretpostavkama koje su neophodne da bi mogli koristiti Bayesove klasifikatore. Prvenstveno se radi o klasom uvjetovanoj neovisnosti i nedostatku podataka o vjerojatnostima. Razne empirijske studije pokazale su da su Bayesovi klasifikatori usporedivi sa drvom odluke i neuronskim mrežama u nekim domenama. Također su korisni jer pružaju teoretske dokaze za ostale klasifikatore koji eksplicitno ne koriste Bayesov teorem. Na primjer, pod određenim pretpostavkama mnoge neuronske mreže kao izlazni rezultat daju maksimum aposteriori hipotezu, kao što radi i Bayesov naivni klasifikator.

3.5.4. Bayesove mreže povjerenja^{XLII}

Bayesove mreže povjerenja snažni su alati za modeliranje uzročno posljedičnih veza, sa vrlo širokim područjem primjene. To su kompaktne mreže vjerojatnosti koje

^{XLII} Bayesove mreže povjerenja-Bayesian Belief Networks,

obuhvaćaju odnose vjerojatnosti među varijablama, kao i povijesnu informaciju o njihovim odnosima.

3.5.4.1 Značajke i primjena Bayesovih mreža povjerenja

Bayesove mreže povjerenja izuzetno su efikasne kod modeliranja situacija gdje su neke informacije već poznate, nadolazeći podaci nisu pouzdani ili su djelomično nedostupni (za razliku od ekspertnih sustava gdje nedostajući i nepouzdana podaci rezultiraju neefikasnim i netočnim rješenjima). Osim toga pružaju konzistentnu semantiku uzročno posljedičnih veza i vjerojatnosti preko intuitivnog grafičkog prikaza. Zbog takvih značajki Bayesove mreže povjerenja se sve više koriste u raznim područjima gdje je potrebno automatizirano "razmišljanje".

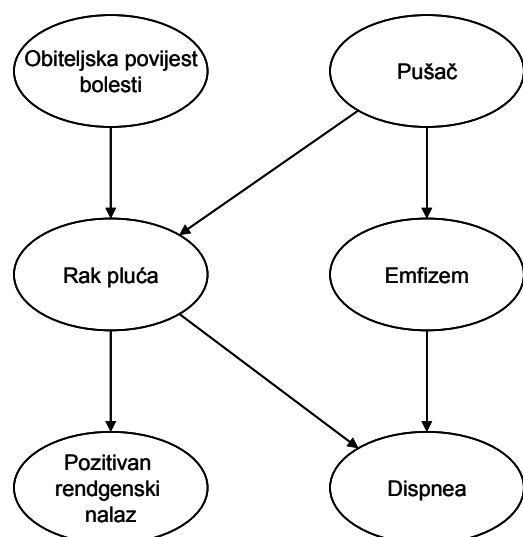
Važno je shvatiti da Bayesove mreže povjerenja ne ovise o poznavanju točne povijesne informacije ili o trenutnom dokazu. One su u stanju producirati vrlo uvjerljive rezultate kada povijesne informacije u CPT-u nisu precizne. S obzirom na to da su ljudi majstori nejasnog lingvističkog interpretiranja znanja (na primjer "sutra će vjerojatno padati kiša") i da nemaju izraženu sposobnost davanja preciznih procjena, posebno je korisna sposobnost Bayesovih mreža da budu efikasne usprkos nejasnoćama i nepreciznostima. Njihova robusnost kod suočavanja sa nesavršenim znanjem, jedan je od mnogobrojnih razloga zašto se učestalo počinju koristiti kao alternativa ostalim oblicima umjetne inteligencije [29].

Pojednostavnjeno, Bayesova mreža povjerenja je model. Može biti model bilo čega: vremena, bolesti i simptoma, vojne postrojbe ili odlaganja otpada. Njihova korist osobito dolazi do izražaja kada su informacije o prošlim događajima ili sadašnjem stanju nekompletne, nejasne, konfliktne i nepouz dane.

3.5.4.2 Teoretski model Bayesovih mreža povjerenja

Naivni Bayesov klasifikator polazi od pretpostavke klasom uvjetovane neovisnosti, što znači da su za dani uzorak vrijednosti atributa međusobno neovisne. Ta pretpostavka pojednostavnjuje i ubrzava izračunavanje. Kada je ova pretpostavka točna Bayesov klasifikator je najtočniji od svih ostalih klasifikatora. Međutim u praksi mogu postojati međusobne ovisnosti između varijabli. Bayesove mreže povjerenja definiraju zajedničku uvjetovanu razdiobu vjerojatnosti. Omogućuju definiranje klasom uvjetovane neovisnosti između podskupova varijabli kao i grafički model uzročnih veza na kojima je moguće provesti i učenje. "Bayesove mreže povjerenja"

nazivaju se još i nazivaju se još i "mreže povjerenja", "Bayesove mreže", i "mreže vjerojatnosti". Bayesova mreža povjerenja definirana je sa dvije komponente. Prva je usmjereni neciklički graf^{XLIII} gdje svaki čvor predstavlja slučajnu varijablu, a svaka strelica predstavlja ovisnost sa određenom vjerojatnošću. Ukoliko je strelica povučena od čvora Y do čvora Z, tada je Y roditelj ili neposredni prethodnik od Z, a Z je sljedbenik od Y. Svaka varijabla je uvjetovano neovisna o onim varijablama koje nisu njezini sljedbenici, tj. nisu međusobno povezane strelicama. Varijable mogu biti diskretne ili kontinuirane. Varijable se mogu podudarati sa stvarnim atributima ili mogu biti "skrivenne varijable" za koje se vjeruje da su povezane (npr. medicinski sindromi u slučaju medicinskih podataka). U Slika 21 prikazana je jednostavna mreža povjerenja za šest Boolean-ovih varijabli preuzeta iz "Artificial Intelligence"[30]. Strelice omogućuju prikaz "uzročnog znanja"^{XLIV}



Na primjer, na rak pluća utiče obiteljska povijest bolesti raka i to je li osoba pušač. Isto tako strelice pokazuju da je varijabla "rak pluća" uvjetovano neovisna od emfizema. To znači da jednom kada su poznate vrijednosti "obiteljske povijesti bolesti" i "pušač", emfizem ne daje nikakvu dodanu informaciju varijabli "rak pluća".

Druga bitna komponenta mreža povjerenja je "tablica uvjetovanih vjerojatnosti"^{XLV} (CPT) za svaku varijablu. CPT za varijablu Z uvjetovanu razdiobu $P(Z|\text{Roditelji}(Z))$ gdje su Roditelji (Z) roditelji ili prethodnici od Z. U Tablica 3 prikazana je CPT za "rak pluća"

Slika 21: Primjer: Jednostavna Bayesova mreža povjerenja

	OPB, P	OPB, ~P	~OPB, P	~OPB, ~P
RP	0,8	0,5	0,7	0,1
~RP	0,2	0,5	0,3	0,9

Tablica 3: Tablica uvjetovanih vjerojatnosti (CPT)

^{XLIII} Usmjereni neciklički graf-Directed Acyclic Graph

^{XLIV} uzročno znanje-Causal knowledge

^{XLV} tablica uvjetovanih vjerojatnosti-Conditional probability table (CPT)

U Tablica 3 su dane vrijednosti za sve moguće kombinacije vrijednosti roditelja.

Tako kombinacija (OPB, P) znači slijedeće:

$$P(\text{"rak pluća"}=\text{"DA"} \mid \text{"Obiteljska povijest bolesti"}=\text{"DA"}, \text{"Pušač"}=\text{"DA"})=0,8$$

Kombinacija (\sim OPB, \sim P) znači slijedeće:

$$P(\text{"rak pluća"}=\text{"NE"} \mid \text{"Obiteljska povijest bolesti"}=\text{"NE"}, \text{"Pušač"}=\text{"NE"})=0,9$$

Zajednička vjerojatnost bilo kojeg uzorka podataka (z_1, \dots, z_n) koji odgovaraju varijablama ili atributima Z_1, \dots, Z_n izračunava se prema izrazu:

$$P(z_1, \dots, z_n) = \prod_{i=1}^n P(z_i \mid \text{Roditelji}(Z_i))$$

gdje su vrijednosti za $P(z_i \mid \text{Roditelji}(Z_i))$ ustvari vrijednosti iz CPT-a.

Bilo koji čvor iz mreže može biti odbran kao "izlazni" čvor koji će predstavljati oznaku klase atributa. Može postojati više izlaznih čvorova. Na mreži se mogu primijeniti i algoritmi za učenje. Tako proces klasifikacije umjesto da rezultira jednom oznakom klase, daje razdiobu vjerojatnosti za attribute oznake klase, što ustvari znači da predviđa vjerojatnosti za pojedine klase.

3.5.5. Učenje Bayesove mreže povjerenja

Kod učenja ili treniranja mreže povjerenja moguće je nekoliko scenarija. Struktura mreže može biti unaprijed poznata, ili može nastajati u procesu na temelju dostupnih podataka. Varijable mreže mogu biti vidljive ili skrivene u svim ili samo u dijelu uzoraka za trening. Slučaj sa skrivenim podacima naziva se još i "nedostajuće vrijednosti" ili nekompletni podaci".

Ukoliko je struktura mreže poznata i varijable su vidljive učenje mreže je jednosmjerno, bez vraćanja na prethodne faze. Vrijednosti iz CPT-a ulaze u izračun, slično kao što se radi kod izračunavanje vjerojatnosti i u naivnoj Bayesovoj klasifikaciji.

Kada je poznata struktura mreže, a neke varijable su skrivene, za učenje mreže povjerenja koristi se metoda iteracije. Objekt uči ulazne vrijednosti iz CPT-a. Neka je S skup uzoraka za trening X_1, X_2, \dots, X_s . Neka su w_{ijk} ulazni podaci iz CPT-a za varijablu $Y_i=y_{ij}$ sa roditeljima $U_i=u_{ik}$. Na primjer, ukoliko je w_{ijk} gornji lijevi podatak iz

CPT (vidi Slika 21) tada je Y_i "rak pluća", a y_{ij} njegova vrijednost "DA", U_i popis roditeljskih čvorova od Y_i {"Obiteljska povijest bolesti" i "pušač"}, a u_{ik} je lista vrijednosti roditeljskih čvorova {"DA","DA"}. Tada su w_{ijk} njihovi međusobni omjeri. Skup omjera označavamo sa w . Omjeri se inicijaliziraju na slučajne vrijednosti. Postupak iteracije je poput penjanja uzbrdo. U svakom koraku iterativnog postupka omjeri se ažuriraju, te počinju konvergirati prema lokalnom optimumu. Metoda traži one w_{ijk} koji će na najbolji mogući način modelirati podatke pod pretpostavkom da je jednaka vjerojatnost bilo kojih mogućih omjera. Cilj je pronaći maksimum od:

$$P_w(S) = \prod_{d=1}^s P_w(X_d)$$

Radi pojednostavnjenja postupak se izvodi praćenjem gradijenta od $\ln P_w(S)$. Ukoliko nam je poznata struktura mreže i w_{ijk} je inicijaliziran postupak se izvodi po slijedećem algoritmu:

1) Izračunavanje gradijenata: Za svaki i,j,k izračunaj

$$\frac{\partial \ln P_w(S)}{\partial w_{ijk}} = \sum_{d=1}^s \frac{P(Y_i = y_{ij}, U_i = u_{ik} | X_d)}{w_{ijk}}$$

Vjerojatnost sa desne strane jednadžbe izračunava se za svaki uzorak za trening X_d u S . Radi jednostavnosti koje predstavljaju Y_i i U_i skrivene za neki X_d tada se pripadajuća vjerojatnost p može izračunati iz dostupnih varijabli iz uzorka koristeći standardne algoritme Bayesovih mreža za zaključivanje.

2) Napraviti mali pomak u smjeru gradijenta: Omjeri se ažuriraju prema izrazu:

$$w_{ijk} \leftarrow w_{ijk} + (l) \frac{\partial \ln P_w(S)}{\partial w_{ijk}}$$

gdje je l mjera učenja ujedno predstavlja veličinu koraka, $\frac{\partial \ln P_w(S)}{\partial w_{ijk}}$ se izračunava prema izrazu u koraku 1. Mjera učenja je konstanta, i obično je malen broj.

3) Ponovna normalizacija omjera: Omjeri w_{ijk} su vrijednosti vjerojatnosti, stoga moraju biti između 0 i 1, te $\sum_j w_{ijk}$ mora biti jednaka za sve i,k . To se postiže ponovnom normalizacijom nakon ažuriranja.

3.6. Poslovna inteligencija-zaključak

Svaki veliki projekt koji uključuje sudjelovanje raznih odjela u jednoj organizaciji osim stručne strane projekta mora imati slijedeće preduvjete za uspjeh:

- definirane osnovne strateške smjernice
- jasno definirana očekivanja top menadžmenta od projekta
- podrška top menadžmenta u provedbi projekta

U većini neuspješnih projekata implementacije BI i DW-a nisu bili ispunjeni neki od ovih preduvjeta, pa usprkos dobro odrađenom tehničkom dijelu posla rezultati su izostali.

Svi su svjesni ogromne važnosti donošenja odluka na temelju valjanih informacija. Uspostava sustava BI kompleksan je proces u kojem rijetki u potpunosti uspijevaju i upravo zato su u prednosti u odnosu na svoju konkurenciju.

4. ISTRAŽIVANJE O PERCEPCIJI FUNKCIJE ODRŽAVANJA

Cilj istraživanja je ustanoviti stanje funkcije održavanja i detektirati slabija područja. Pitanja obuhvaćaju djelatnost funkcije održavanja, a uključuju strateški i operativni dio sa naglaskom na CMMS.

Područje održavanja odabrano je zbog toga jer u hrvatskoj još nije u praksi u potpunosti zaživio pristup koji se opisuje u gospodarenju tehničkim sustavima. Najbliže tome je funkcija održavanja pa je stoga održavanje odabrano kao relevantni pokazatelj za ovo ispitivanje.

4.1. Sadržaj istraživanja

Istraživanje je provedeno prema pitanjima izabranim iz [31].

Anketiranima je predan dvostrano ispisan list sa petnaest pitanja i kratkim uputama za ispunjavanje (Tablica 4).

4.1.1. Ispitanici

Ispitivanje je obuhvatilo tri velike hrvatske tvrtke iz prehrambene i farmaceutske industrije. Tvrtke spadaju u grupu velikih (godišnja prodaja veća od 100 milijuna €, broj zaposlenih veći od 700). Ispitanike možemo podijeliti u dvije grupe. U prvu grupu spadaju menadžeri koji se organizaciono nalaze iznad funkcije održavanja (uključujući i direktora održavanja), a druga grupa su menadžeri iz proizvodnje. Ovim kriterijima broj ispitanika je ograničen, pa je u ovom istraživanju obrađeno deset anketnih listića. Unutar navedene grupe ispitivanje je anonimno, uz napomenu da će rezultati biti korišteni isključivo za akademske svrhe.

4.2. Rezultati istraživanja

U Tablica 5 "Rezultati istraživanja"- prikazane su za sve ispitanike njihove ocjene svih pitanja na skali od 1 do 10. Dobivene rezultate potrebno je analizirati kako bi se otkrilo koja su područja slabija.

Istraživanje se provodi u svrhu znanstveno istraživačkog rada, stoga molim da na sva pitanja odgovorite iskreno. Na pitanja odgovarate zaokruživanjem jednog od ponuđenih brojeva. Ukoliko smatrate da je tvrdnja u potpunosti točna zaokružujete broj 10, a u suprotnom broj 1, ili jedan od ostalih brojeva ukoliko se tvrdnja nalazi negdje između.

- | | |
|--|----------------------|
| 1. Jesu li menadžeri održavanja uključeni u strateško planiranje visokog nivoa? Jesu li menadžeri održavanja shvaćeni ozbiljno? | 1 2 3 4 5 6 7 8 9 10 |
| <hr/> | |
| 2. Da li je viši menadžment posvećen dugoročnom povećanju kvalitete i smanjenju cijene održavanja? Postoje li sredstva osigurana za opravdane investicije sa navedenim ciljem? | 1 2 3 4 5 6 7 8 9 10 |
| <hr/> | |
| 3. Posjeduje li menadžer održavanja dovoljno znanja kako bi kritički evaluirao investiciju sa financijskog aspekta? | 1 2 3 4 5 6 7 8 9 10 |
| <hr/> | |
| 4. Da li proces budžetiranja doprinosi na najbolji mogući način dugoročnim interesima organizacije, te da li sprečava propadanje nepokretne imovine? | 1 2 3 4 5 6 7 8 9 10 |
| <hr/> | |
| 5. Postoji li petogodišnji ili desetogodišnji strateški plan održavanja koji uključuje kapitalne zamjene, a koji revidiraju i ažuriraju jednom godišnje održavanje, operacije i viši menadžment? | 1 2 3 4 5 6 7 8 9 10 |
| <hr/> | |
| 6. Postoji li poseban budžet za unapređenja u održavanju i za provođenje eksperimenata koji bi poboljšali podobnost za održavanje? | 1 2 3 4 5 6 7 8 9 10 |
| <hr/> | |
| 7. Da li se troškovi energije i kapitalne zamjene u budžetu promatraju zajedno sa troškovima održavanja? Je li moguće opravdati ulaganja u održavanje smanjenim troškovima energije i produženjem životnog vijeka imovine? | 1 2 3 4 5 6 7 8 9 10 |
| <hr/> | |

8. Postoje li redoviti sastanci između održavatelja i korisnika njihovih usluga radi postavljanja prioriteta?	1 2 3 4 5 6 7 8 9 10
9. Smatrate li da radnici održavanja i njihovi poslovođe imaju edukaciju, znanje, pozitivan stav i pristup CMMS-u ^{XLVI} ?	1 2 3 4 5 6 7 8 9 10
10. Da li je prema vašem znanju CMMS vjerodostojan što se tiče lažnih podataka i smeća?	1 2 3 4 5 6 7 8 9 10
11. Smatrate li da su podaci u CMMS-u točni i korisni?	1 2 3 4 5 6 7 8 9 10
12. Prema vašem iskustvu da li je CMMS sposoban izlučiti problematičnu opremu, zaposlenike ili dijelove?	1 2 3 4 5 6 7 8 9 10
13. Jesu li izvješća u papirnatom obliku tako koncipirana da vam daju samo onaj nivo informacija koji vas zanima, a dodatne informacije moguće je dobit na zahtjev? Jesu li jednostranična izvješća za menadžment koja prikazuju operativne parametre i trendove dostupna menadžmentu izvan održavanja?	1 2 3 4 5 6 7 8 9 10
14. Jeste li čuli za ponovljene skupe zastoje koji bi automatski pokrenuli istragu za otkrivanje uzroka zastoja te njegovo uklanjanje?	1 2 3 4 5 6 7 8 9 10
15. Jesu li rutinski poslovi održavanja obavljeni prema planu, na vrijeme, unutar zadanog budžeta?	1 2 3 4 5 6 7 8 9 10

Tablica 4: Anketni list

^{XLVI} CMMS- Computerized Maintenance Information System-Računalom podržani informacijski sustav održavanja

		ISPITANICI									
		1	2	3	4	5	6	7	8	9	10
P I T A N J A	1.	3	7	3	1	3	3	3	2	3	2
	2.	6	6	7	5	4	4	8	8	6	5
	3.	9	8	2	9	3	9	9	5	8	7
	4.	7	8	5	1	3	6	5	6	7	6
	5.	3	4	5	9	1	3	7	4	3	4
	6.	4	3	1	1	2	1	1	1	4	1
	7.	3	8	8	8	4	8	8	8	3	8
	8.	9	8	10	10	6	6	10	10	10	10
	9.	7	7	9	8	7	3	9	9	8	8
	10.	7	4	5	5	3	7	8	8	7	6
	11.	8	4	10	5	8	8	9	9	7	7
	12.	2	4	6	8	7	9	8	6	5	3
	13.	7	4	4	6	3	5	8	2	7	2
	14.	7	8	4	9	5	8	2	3	7	8
	15.	9	7	3	8	9	6	9	7	9	7

Tablica 5: Rezultati istraživanja

4.3. Metoda analize

Za klasifikaciju pitanja ovisno o rezultatima ankete odabrana je klaster analiza.

Cilj klaster analize je grupiranje subjekata u klastere, tako da je svaki klaster što je više moguće homogen s obzirom na varijable klasteriranja. Prvi korak u klaster analizi je odabir mjere sličnosti, a zatim slijedi donošenje odluke o tipu tehnike klasteriranja koju ćemo koristiti (hijerarhijska ili nehijerarhijska). Treći korak je odabir tipa metode klasteriranja za odabranu tehniku (npr. centroidna metoda u hijerarhijskoj tehnici klasteriranja). U četvrtom koraku donosimo odluku s obzirom na broj klastera. Na kraju slijedi interpretacija rezultata.

Hijerarhijske metode ne zahtijevaju *a priori* poznavanje broja klastera. Nedostatak hijerarhijskih metoda je u tome da jednom dodijeljeni subjekt ne možemo preraspodijeliti u drugi klaster. Zbog toga će se u ovom istraživanju hijerarhijska metoda koristiti u svrhu otkrivanja klastera, a tako dobiveno rješenje će se dodatno pročisti nehijerarhijskim metodama.

4.3.1. Hijerarhijska klaster analiza

Hijerarhijska klaster analiza je provedena korištenjem više metoda.

- Centroid metoda
- Metoda najbližeg susjeda ili metoda jedne veze
- Metoda najudaljenijeg susjeda, ili metoda potpune povezanosti
- Metoda prosječne povezanosti
- Ward-ova metoda

4.3.2. Interpretacija rezultata hijerarhijske klaster analize

Ovisno o korištenoj metodi postoje određene razlike u formiranju klastera. Bitnim smatram slijedeću činjenicu: Sve metode izlučile su pitanja 1, 5, 6 i 13 u jedan klaster i to obično u vrlo ranim koracima (vidi Slika 22). U većini metoda lijepo su izražena tri klastera koja načelno možemo nazvati slijedećim imenima:

- 1.) Uvjerljivo loše ocjenjena pitanja
- 2.) Raznoliko ocjenjivana pitanja
- 3.) Visoko ocijenjena


Ovisno o metodi postoje razlike između dugog i trećeg klastera, dok su u metodi prosječne povezanosti spojene u jedan klaster.

4.3.3. Interpretacija rezultata nehijerarhijske klaster analize

Dodatnim ispitivanjem rezultata dobivenih hijerarhijskom metodom korištenjem nehijerarhijske klaster analize potvrđeni su prethodno dobiveni rezultati. Ponovno su pitanja 1,5, 6, 13 izvučena u isti klaster.

* * * * * H I E R A R C H I C A L C L U S T E R A N A L Y S I S * * *

Dendrogram using Centroid Method



Slika 22: Rezultati klaster analize prikazani u dendrogramu

4.4. Zaključak istraživanja

Kako je cilj ovoga istraživanja bio identifikacija slabijih područja, a u svih pet metoda su jednoznačno identificirana ista pitanja u klaster "Uvjerljivo loše ocjenjena pitanja" čime je cilj istraživanja je ostvaren.

U daljnjem znanstveno istraživačkom radu fokus će biti na pitanjima 1, 5, 6, 13.

Iz odgovora proizašlih iz ovoga istraživanja može se zaključiti slijedeće:

- menadžeri održavanja nisu dovoljno uključeni u strateško planiranje visokog nivoa i nisu shvaćeni ozbiljno
- ne postoji petogodišnji ili desetogodišnji strateški plan održavanja koji uključuje kapitalne zamjene, a koji revidiraju i ažuriraju jednom godišnje održavanje, operacije i viši menadžment?
- ne postoji poseban budžet za unapređenja u održavanju i za provođenje eksperimenata koji bi poboljšali podobnost za održavanje?

- papirnata izvješća nisu pravilno koncipirana i nisu dostupna svima zainteresiranim

Dobiveni rezultati jasno su identificirali u kojem pravcu trebaju ići potrebna unapređenja. Na prvi pogled čini se da je neka unapređenja moguće postići jedino organizacijskim promjenama (uključenost menadžera održavanja u strateško planiranje). Postoji nekoliko razloga zašto organizacione promjene nisu uvijek najpovoljnije rješenje takvih problema. Prvi je svakako taj što je svaka reorganizacija dugotrajan, mukotrpan i skup proces, koji ponekad može izazvati kratkotrajne probleme u redovitom poslovanju. Slijedeći glavni nedostatak je taj što reorganizacija neće nužno promijeniti način rada i razmišljanja pojedinih ljudi, te neće nužno inicirati rješavanje problema na nov način.

Na koji način omogućiti da funkcija održavanja bude uključena u strateško planiranje višeg nivoa? Zašto nije važno da menadžeri održavanja budu direktno uključeni u strateško planiranje visokog nivoa? Važno je da u strateškom planiranju visokog nivoa budu uključene informacije i znanja koja imaju rukovoditelji održavanja. To znači da je prilikom donošenja strateških odluka potrebno razmatrati ne samo financijske i tržišne aspekte već informacije nastale u sustavu gospodarenja tehničkim sustavima. Naravno da time nismo u potpunosti riješili nesudjelovanje menadžera održavanja u procesu donošenja strategije. Ono što je izuzetno bitno je i to da strategija bude poznata i dostupna ostalim zaposlenicima koji nisu sudjelovali u njezinom kreiranju. Mora postojati dvosmjerni tok informacija.

Slijedeći problem kojim će se baviti su nezadovoljavajuća izvješća. Glavni razlog tome što korisnici nisu zadovoljni izvješćima su informacije koje ta izvješća pružaju.

Da li postoji nešto što može riješiti oba problema? Sustav poslovne inteligencije. Implementacijom sustava poslovne inteligencije poboljšat će se dostupnost i tijek informacija, a samim time i izvještavanje će biti unaprijeđeno.

Što se tiče preostala dva problema:

- ne postoji petogodišnji ili desetogodišnji strateški plan održavanja koji uključuje kapitalne zamjene, a koji revidiraju i ažuriraju jednom godišnje održavanje, operacije i viši menadžment?
- ne postoji poseban budžet za unapređenja u održavanju i za provođenje eksperimenata koji bi poboljšali podobnost za održavanje?

Oni neće biti riješeni uvođenjem poslovne inteligencije, ali će poslovna inteligencija omogućiti njihovo kvalitetnije i lakše rješavanje.

Ipak ovaj problem pokušati će se riješiti u nastavku primjenom modela odlučivanja uz korištenje poslovne inteligencije.

5. MODEL GOSPODARENJA KORIŠTENJEM POSLOVNE INTELIGENCIJE

U poglavlju 2, obrađeni su pristupi gospodarenju tehničkim sustavima, a u poglavlju 3 "Poslovna Inteligencija". Na području gospodarenja tehničkim sustavima napravljeni su veliki pomaci u odnosu na vrijeme kada je održavanje bilo glavni način gospodarenja opremom. Cilj gospodarenja opremom je imati maksimalni profit životnog vijeka opreme LCP ili ovisno o pristupu minimalni trošak životnog vijeka opreme LCC. Kako neka tvrtka može koristiti opremu na profitabilniji način nego što je moguće praćenjem profita životnog vijeka opreme? Gdje je tu uloga poslovne inteligencije? U poglavlju 4 provedeno je istraživanje i otkriveni problemi u funkciji održavanja. U nastavku rada pokušati će se kreirati rješenje koje bi uklonilo neke od navedenih problema iz istraživanja.

5.1. Interesi i ciljevi pojedinih dijelova tvrtke

Na prvi pogled možemo zaključiti: ukoliko ostvarujemo maksimalni profit životnog vijeka opreme, to će biti jedan od temelja za uspješno poslovanje tvrtke i ostvarenje njenog maksimalnog profita! Ta tvrdnja je donekle točna!

Ako krenemo od svima poznate zakonitosti "Suma parcijalnih optimuma rijetko kada predstavlja i ukupni optimum" možemo krenuti od slijedećih pretpostavki. U znanosti se puno puta dogodilo da određene zakonitosti vrijede u 99,9% slučajeva, ali ne pokrivaju sve!

Ovdje želim reći da postoje situacije kada na primjer, maksimalan LCP neće nužno generirati maksimalan $EBIT^{XLVII}$ (profit prije kamata i oporezivanja) jer neki drugi generatori profita tvrtke mogu biti veći od onih koje smo "izgubili" kroz LCP koji nije maksimalan. Da je takvu vezu moguće jednoznačno i jednostavno definirati to bi već odavno bilo napravljeno. Jesu li se događale takve situacije? Naravno da jesu! Primjer su neke uspješne strateške odluke koje sa aspekta LCP-a nisu optimalne.

Danas se može pronaći izuzetno veliki broj istraživanja, metoda i uspješnih rješenja koja se bave problemom uspješnog gospodarenja proizvodnom opremom u situacijama kada je potreba za kapacitetima veća od trenutno ostvarene. Postoji i

^{XLVII} EBIT-Earnings Before Interests and Taxes

druga situacija koja je dosta česta, ali se o njoj toliko ne istražuje. Radi se u slučaju kada postoji višak proizvodnih kapaciteta. Nekoliko razloga može dovesti do takve situacije. Najgora moguća situacija je pad potražnje za proizvodom, pa proizvodna oprema proizvodi malim kapacitetima. Takav slučaj može se dogoditi ulaskom konkurentna na tržište. To je česta pojava u Hrvatskoj.

Druga je situacija koja se javlja prilikom spajanja dvije kompanije sa međusobno sličnim proizvodnim programom i proizvodnom opremom. Kod takvih situacija i okrupnjivanja tvrtki događaju se slijedeće situacije:

- ukidaju se neki proizvodi ukoliko su međusobno konkurirali
- ukidaju se proizvodi manji po vrijednostima i količinama
- dolazi do specijalizacija pojedinih pogona za određene tehnologije ili vrste proizvoda

Sve ovo navedeno dovest će do toga da se smanje zahtjevi za proizvodnim kapacitetima na određenoj vrsti opreme. Gledajući iz tog aspekta problem je moguće smatrati jednakim kao i prethodno opisani.

Ukupni poslovni prihodi (mil. kn)	3.329,3
Ukupna prodaja (mil. kn)	3.294,9
Prihodi od prodaje u zemlji (mil. kn)	1.769,1
Prihodi od prodaje u inozemstvu (mil. kn)	1.525,8
ebit (Dobit prije kamata i poreza) (mil. kn)	154,3
ebitda (mil. kn)	384,2
Neto dobit (mil.kn)	84,2
eps (zarada po redovnoj dionici)	16,0
Ukupna imovina (mil. kn)	3.416,5
Kapital i rezerve (equiti) (mil. kn)	1.879,4
Novčani tok (mil.kn)	116,1
Broj zaposlenih	7.283
Neto dobit / broj zaposlenih (000 kn)	11,6
roe (Povrat na kapital)	4,5
Investicije u materijalnu imovinu (mil. kn)	118,6

Tablica 6: Ključni pokazatelji poslovanja grupe Podravka za 2004. godinu

Polazimo od pretpostavke da je u interesu tvrtke ostvarivanje maksimalnog profita naravno uz uvjet da takav maksimalni profit neće biti ostvaren jednokratno, kratkoročno ukidanjem investicija. U svrhu ilustracije poslužit će Tablica 6: *Ključni pokazatelji poslovanja grupe Podravka za 2004. godinu*.

Što je moguće zaključiti iz pokazatelja poslovanja? Koji pokazatelji su interesantni i kome? Ako krenemo od dioničara, njih u prvom redu interesira EPS (zarada po redovnoj dionici). Njima je u interesu da taj EPS bude što viši. Osim toga zanimaju ih ukupni poslovni prihodi i EBIT, koji im pružaju malo precizniju informaciju o stanju tvrtke u koju su uložili svoj novac.

Članovima uprave na prvom mjestu je EBIT i Neto dobit koji isto tako moraju biti što je moguće viši. Druga linija menadžmenta ima različite interese ovisno o području kojim se bavi, ali ako je riječ o menadžerima zaduženima za proizvodnju, na prvom mjestu im je ostvarenje proizvodnih planova uz što niži COGS^{XLVIII} (trošak proizvedenih proizvoda). Niži menadžer biti će zainteresiran za ostvarenje proizvodnih planova i za što je moguće viši budžet koji bi imao na raspolaganju kako bi što lakše ostvario proizvodne planove. Ostvarenje proizvodnih planova i COGS su pokazatelji pomoću kojih srednji menadžment procjenjuje niži. Kako bi uspješno upravljao dotičnim pokazateljima niži menadžer ima "svoje" pokazatelje pomoću kojih će upravljati onim resursima za koje je odgovaran. Neki od njih su na primjer LCC i LCP.

5.2. Uvjeti koji moraju biti ostvareni za optimalan rezultat cijele tvrtke

U većim tvrtkama obično postoje tri nivoa menadžmenta (vidi Sliku 23: Nivoi menadžmenta). To su strategija, taktika i operativa.

Svaki nivo prvenstveno vodi brigu o svojem području, a donekle je upućen u jedan nivo niže. Bez obzira na to koliko je dobro posložena organizacija tvrtke, te koliko su efikasne linije izvještavanja odozdo prema gore kao i protok informacija odozgo prema dolje, gotovo je nemoguće očekivati da će za odluku na bilo kojem nivou biti evaluirane sve informacije koje mogu imati utjecaja na konačan rezultat. Zbog toga je za donošenje odluke bez obzira o kojem se nivou radi potrebno uključiti sve relevantne čimbenike.

^{XLVIII} COGS-Cost of Goods Sold



Slika 23: Nivoi menadžmenta

Postoje alati koji donekle mogu poboljšati tu situaciju (vidi poglavlje 2.9.1 Sustav uravnoteženih ciljeva-BSC, str. 32), ali i takvi alati daju će parcijalne rezultate bez određene infrastrukture za gospodarenje znanjem i informacijama. Tu infrastrukturu pruža Poslovna inteligencija (vidi Slika 16: Infrastruktura BI sustava)

Ukratko rečeno, da bi mogli donositi optimalne odluke potrebno je obuhvatiti sva tri nivoa upravljanja tvrtkom, što omogućuje poslovna inteligencija.

5.2.1. Razgraničenja između strateškog, taktičkog i operativnog nivoa

Svima je otprilike poznato što znači strategija, taktika i operativa. Kako je moguće preciznije definirati što je koji nivo i koje su granice između njih? Da bi mogli odrediti granice, najprije je potrebno odrediti varijablu prema kojoj će se uspoređivati i razgraničavati. Piramida na Slika 23: Nivoi menadžmenta je hijerarhijska i može nas navesti da povučemo granice na određenim organizacijskim nivoima. Takav pristup ima jedan nedostatak! Iako se pojedini nivoi menadžmenta pretežno bave predmetima iz svoga nivoa imamo situacije da se i najviši menadžment ponekad bavi operativnim odlukama, a isto tako i niži menadžment može participirati u strateškim odlukama!

U čemu se najviše razlikuju strategija taktika i operativa? Kako vide rezultati svake od njih?

Odgovor na pitanja je "vrijeme"! Kada donesemo neku operativnu odluku, pitanje je dana ili tjedna kada će se pokazati njezina opravdanost. Nasuprot tome kod strategije mogu proći i godine prije nego se pokaže jesu li uspješne ili ne!

Sada kada je određena varijabla, u drugom koraku je potrebno je odrediti granice koje će se nalaziti na određenoj veličini te varijable.

Krenimo od strategije. Koji je to vremenski horizont za strategiju? Da li je on isti u raznim industrijama ili čak u nekim drugim područjima? Za određivanje vremenskog horizonta strategije može se krenuti sa slijedećim pitanjem: "Nakon kojeg vremena će biti opipljivi rezultati strategije?" Ako se ograničimo na proizvodnu industriju to vrijeme uključuje:

- vrijeme za razvoj proizvoda
- vrijeme za stvaranje proizvodnih kapaciteta
- vrijeme proizvodnje
- vrijeme za pozicioniranje na tržištu

Suma svih ovih vremena dati će nam odgovor koliki je strateški horizont. Kako nas zanima konkretna brojka pokušati ćemo odrediti strateški horizont za razne industrije.

Faza	Prehrambena	Farmaceutska	Auto
razvoj proizvoda	1g	10-15g	3g
stvaranje proizvodnih kapaciteta	1-2g	1-3g	1-2g
proizvodnja	1mj	1mj	1mj
pozicioniranje na tržištu	1-3mj	6mj	1g
Vremenski horizont	2g	15g	5g

Tablica 7: Strateški horizonti raznih industrija

Kao što se vidi iz Tablica 7: Strateški horizonti raznih industrija dosta se razlikuju. To znači da se ne može jednoznačno odrediti koja je granica strateškog horizonta.

Radi se naravno o gornjoj granici strategije.

Slijedeća granica je taktička. Tu je situacija znatno jednostavnija nego kod strategije. U današnje vrijeme sva dioničarska društva moraju minimalno jednom godišnje izvještavati svoje rezultate. Isto tako proces budžetiranja radi se na nivou godine. Iz svega toga možemo zaključiti da nam je taktički nivo na vremenskom horizontu jedne

godine. Kod operativnog nivoa situacija je isto tako jednostavna. Operativni planovi rade se za tjedan i mjesec kao terminsku jedinicu, pa tako možemo zaključiti da je mjesec gornja granica za operativni nivo.

5.3. Model donošenja odluka

Pred model donošenja odluka postavlja se zadatak da uključi relevantne pokazatelje iz svih organizacionih nivoa, te da definira utjecaj pojedinog nivoa na konačan rezultat.

5.3.1. Osnovni uvjet modela

Osnovni uvjet koji mora ispunjavati odluka ukratko glasi:

$$O = \max[f(ST, TA, OP)]$$

Jednadžba 1: Osnovni uvjet modela donošenja odluka

gdje su:

O	Optimalna odluka
ST	Strateški nivo
TA	Taktički nivo
OP	Operativni nivo

Jednadžba 1) opisuje kako je optimalna odluka (**O**) maksimum funkcije strateškog (**ST**), taktičkog (**TA**) i operativnog nivoa (**OP**). Funkcija f definira na koji način će svaki od nivoa utjecati na rezultat, pa je zbog toga možemo nazvati funkcija utjecaja.

5.3.2. Definiranje funkcije utjecaja

Funkcija utjecaja odredit će koliko svaki od pojedinih nivoa doprinosi krajnjem rezultatu.

$$f(ST, TA, OP) = \alpha ST + \beta TA + \gamma OP$$

Jednadžba 2: Funkcija utjecaja

gdje je

α	koeficijent utjecaja strateškog nivoa
β	koeficijent utjecaja taktičkog nivoa
γ	koeficijent utjecaja operativnog nivoa

Jedinica u kojoj će biti izražen rezultat neće biti novac! Postoji nekoliko razloga za takav pristup. Najvažniji je taj što nije moguće sve utjecaje svesti direktno na novac. Kada imamo situaciju da je sve jednostavno moguće iskazati kroz novac, onda se koriste financijske evaluacije.

5.3.2.1 Strateški dio funkcije utjecaja

Strateški dio je najteže izraziti novčano. Moguće ga je izraziti na temelju nekih pretpostavki, planova prodaje, ali bez obzira na to o koliko se dobrom i preciznom modelu predviđanja radilo, uvijek postoji određena nesigurnost.

Ako krenemo od Jednadžba 2: Funkcija utjecaja, vidi se da njen strateški dio glasi:

$$\alpha \cdot ST$$

Jednadžba 3: Strateški dio funkcije utjecaja

gdje je

ST realan broj takav da je $\langle -1 \leq ST \leq 1 \rangle$

α realan broj, takav da je $\langle 0 \leq \alpha \leq 0,3 \rangle$

ST će odgovarati na osnovno pitanje: "Da li je odluka koju donosimo u skladu sa strategijom tvrtke i strategijom poslovne aktivnosti odjela/divizije?"

Ovisno o odgovoru ST će poprimati slijedeće vrijednosti:

Vrijednost	Odgovor
-1	Odluka nije u skladu sa strategijom
0	Odluka nema nikakve veze sa strategijom
1	Odluka je u skladu sa strategijom

Na postavljena pitanja biti će moguće dati više od ova tri odgovora. Postojati će određene situacije kada će prva i treća tvrdnja biti donekle ublažene, pa će se u tim slučajevima vrijednosti ST -a pomicati prema 0.

Ovdje naravno nije moguće dati generalno definirati i određene vrijednosti koje se nalaze između -1 i 0, te između 0 i 1. Kako će se onda dodjeljivati takve ocjene? To će naravno ovisiti o kojoj se industriji radi, pa čak i kojoj se tvrtki radi. Drugim riječima nekakve međugranice će biti potrebno definirati ovisno o konkretnoj situaciji. Ne prate

sve tvrtke iste pokazatelje, niti određena vrijednost nekog pokazatelja neće imati jednaku važnost u raznim tvrtkama.

Koeficijent α poprimati će vrijednosti ovisno o odgovoru na pitanje: "Da li provedbom ove odluke utječemo na provođenje strategije tvrtke i strategije poslovne aktivnosti (odjela/divizije)"

Ovisno o odgovoru α će poprimati slijedeće vrijednosti.

Vrijednost	Odgovor
0	Odluka nema nikakvog utjecaja na provođenje strategije
0,3	Odluka utječe na provođenje strategije

Bitno je naglasiti da će se vrijednost 0,3 poprimiti odluke koje bitno doprinose strategiji, kao i one koji imaju značajan negativan utjecaj na provođenje strategije.

Opet dolazimo do pitanja kako će se dodjeljivati vrijednosti koje se nalaze između? Naravno da je moguće postaviti mnogo kriterija i pokazatelja, ali opet neko generalno rješenje nije moguće dati, jer konkretne situacije će se razlikovati.

5.3.2.2 Taktički dio funkcije utjecaja

Taktički dio funkcije utjecaja bilo bi lako izraziti novčano. Međutim kako se sve vrijednosti u funkciji utjecaja zbrajaju, potrebno je sve vrijednosti svesti na zajednički nazivnik.

Ako krenemo od Jednadžba 2: Funkcija utjecaja vidi se da njen taktički dio glasi:

$$\beta \cdot TA$$

Jednadžba 4: Taktički dio funkcije utjecaja

gdje je:

TA realan broj takav da je $\langle -1 \leq TA \leq 1 \rangle$

β realan broj, takav da je $\langle 0 \leq \beta \leq 0,3 \rangle$

TA će odgovarati na osnovno pitanje: Kako odluka koju donosimo utiče na financijske rezultate?"

Ovisno o odgovoru TA će poprimati slijedeće vrijednosti:

Vrijednost	Odgovor
-1	Odluka ima negativan utjecaj na financijske rezultate
0	Odluka nema nikakvog utjecaja na financijske rezultate
1	Odluka ima pozitivan utjecaj na financijske rezultate

Na postavljena pitanja biti će moguće dati više od ova tri odgovora. Postojati će određene situacije kada će prva i treća tvrdnja biti donekle ublažene, pa će se u tim slučajevima vrijednosti TA-a pomicati prema 0.

Ovdje opet dolazimo do situacije kako definirati vrijednosti koje se nalaze izvan ovdje navedenih u tablici? Čak i u tvrtkama u kojima se ne prati puno pokazatelja sigurno postoji dosta financijskih pokazatelja. Kao i kod strateškog dijela funkcije odlučivanja, konkretne vrijednosti ovisit će o industriji, tvrtki i situaciji u kojoj se tvrtka nalazi. Na primjer neka tvrtka koja posluje sa visokom likvidnošću, odnosno solidnim iznosima slobodnog kapitala, puno lakše će donijeti odluku o investiranju od one koju muče problemi sa likvidnošću. Nadalje ukoliko je za navedenu investiciju potrebno uzeti kredit, to povisuje cijenu kapitala pa se ta razlika još dodatno povećava.

Koeficijent β poprimati će vrijednosti ovisno o odgovoru na pitanje: "U kojoj mjeri provedbom ove odluke utječemo na financijske rezultate tvrtke"

Ovisno o odgovoru α će poprimati slijedeće vrijednosti:

Vrijednost	Odgovor
0	Odluka nema nikakvog utjecaja na financijske rezultate tvrtke
0,3	Odluka značajno utječe na financijske rezultate tvrtke

Bitno je naglasiti da će vrijednost 0,3 poprimiti odluke koje bitno poboljšavaju financijske rezultate tvrtke, kao i one koji imaju značajan negativan utjecaj na financijske rezultate tvrtke.

Ovdje je dodjeljivanje vrijednosti nešto jednostavnije nego jer bi prilično dobar pokazatelj bio apsolutni ili relativni novčani iznos.

5.3.2.3 Operativni dio funkcije utjecaja

Ako krenemo od Jednadžba 2: Funkcija utjecaja vidi se da njen operativni dio glasi:

$$\gamma \cdot OP$$

Jednadžba 5: Operativni dio funkcije utjecaja

gdje je:

OP realan broj takav da je $\langle -1 \leq OP \leq 1 \rangle$

Y realan broj, takav da je $\langle 0 \leq \gamma \leq 0,4 \rangle$

OP će odgovarati na osnovno pitanje: "Kako će odluka koju donosimo utjecati na provođenje planova proizvodnje?"

Ovisno o odgovoru OP će poprimati slijedeće vrijednosti:

Vrijednost	Odgovor
-1	Odluka ima negativan utjecaj na ostvarenje planova proizvodnje
0	Odluka nema nikakvog utjecaja na ostvarenje planova proizvodnje
1	Odluka ima pozitivan utjecaj na ostvarenje planova proizvodnje

Na postavljena pitanja biti će moguće dati više od ova tri odgovora. Postojati će određene situacije kada će prva i treća tvrdnja biti donekle ublažene, pa će se u tim slučajevima vrijednosti OP-a pomicati prema 0.

Koeficijent γ poprimati će vrijednosti ovisno o odgovoru na pitanje: "U kojoj mjeri provedbom ove odluke utječemo na ostvarenje planova proizvodnje "

Ovisno o odgovoru α će poprimati slijedeće vrijednosti.

Vrijednost	Odgovor
0	Odluka nema nikakvog utjecaja na ostvarenje planova proizvodnje
0,4	Odluka značajno utječe na ostvarenje planova proizvodnje

Bitno je naglasiti da će vrijednost 0,4 poprimiti odluke koje bitno pospješuju ostvarenje planova proizvodnje, kao i one koji imaju značajan negativan utjecaj na ostvarenje planova proizvodnje.

5.3.3. Kriterij prihvatljivosti modela

Funkcija odluke $f(ST, TA, OP) = \alpha ST + \beta TA + \gamma OP$ može poprimiti vrijednosti koje se nalaze na intervalu $\langle -1 \leq f(ST, TA, OP) \leq 1 \rangle$.

Kriterij prihvatljivosti neće biti neki konkretan broj. Naravno ukoliko bi prema modelu odluka bila idealna, tada bi vrijednost funkcije odluke iznosila 1. Glavna svrha modela je da natjera korisnika da istraži i ostale informacije kojima ne barata tako često i da mu pruži okvirnu procjenu odluke.

Kako je riječ o orijentacionom modelu gdje nije do kraja egzaktno definirano dodjeljivanje vrijednosti pojedinim dijelovima funkcije utjecaja, zbog toga i kriterij prihvatljivosti neće biti definiran nekom strogom granicom, već će imati karakter smjernica.

Vrijednost $f(ST, TA, OP)$	Odgovor
-1....-0,5	Odbaciti odluku
-0,5-0,5	Preispitati prednosti i nedostatke predložene odluke, prihvatiti samo ako ne postoji bolja alternativa
0,5-1	Prihvatiti odluku

Ukoliko se modelom radi usporedba dvije odluke različite odluke, naravno da će bolja biti ona kod koje je vrijednost funkcije viša.

5.3.4. Uloga poslovne inteligencije u određivanju pojedinih vrijednosti funkcije utjecaja

Ovaj model za donošenje odluka je jednostavan sa teoretskog aspekta. Međutim kada se krene u njegovu primjenu, nastupaju problemi. Donijeti procjenu usklađenosti neke odluke sa strategijom, pa utjecaj te odluke na financijske rezultate, sve su stvari do kojih nije jednostavno doći. Postoje dva načina: jedan je istraživanje svih podataka iz dostupnih operativnih baza podataka, prikupljanje informacija od osoba zaduženih za pojedine procese, a vrlo često i procjena određenih stvari. Drugi način je korištenje poslovne inteligencije i njezine infrastrukture (skladišta podataka, alati data mininga, hardware koji sve to podržava, vidi Slika 16: Infrastruktura BI sustava). Ukoliko je sustav poslovne inteligencije pravilno i u cijelosti implementiran u

tvrtki, tada su njemu dostupne sve informacije, iz kojih svojim alatima kreira znanje. To znanje koje je kreirano iz enormno velikog broja podataka ulazi u model.

Slijedeća korist koju donosi ovaj model uz primjenu poslovne inteligencije je rješavanje problema dijagnosticiranog u poglavlju 4.3.2 Interpretacija rezultata hijerarhijske klaster analize, str. 79.

Naravno da je moguće i otići korak dalje. Navedeni model može se prevesti u Bayesovu mrežu povjerenja, koju zatim istreniramo na temelju ispravno donesenih odluka i tako dobijemo mogućnost da takva jedna mreža povjerenja u budućnosti samostalno donosi odluke.

Kreiranje Bayesove mreže povjerenja i njezino treniranje je zahtjevan problem koji nije predmet ovoga rada, ali svakako zaslužuje detaljnije istraživanje zbog mogućnosti koje pruža.

6. TESTIRANJE MODELA

Model gospodarenja tehničkim sustavima korištenjem poslovne inteligencije testirat će se kroz studije slučaja. U prvoj fazi to će biti odluka donesena samo na bazi tehničkih informacija, dok će u drugoj fazi biti primijenjen model gospodarenja tehničkim sustavima korištenjem poslovne inteligencije. Usporedbom dobivenih rezultata na posredan će način preko modela biti testirana i hipoteza (vidi poglavlje 1.1, str.2). U poglavlju 6.1 slijedi uvod u događaj koji se opisuje u poglavlju 6.2. Nakon toga u poglavlju 6.3 rješava se isti problem, no ovaj puta primjenjuje se model donošenja odluka uz korištenje poslovne inteligencije.

6.1. Opis obrađivanoga problema

6.1.1. Situacija u tvrtki

Tvrtka koja se bavi istraživanjem, razvojem, proizvodnjom i prodajom farmaceutskih proizvoda ima više dislociranih proizvodnih lokacija. Četiri lokacije su na jednom kontinentu dok je jedna lokacija na drugom kontinentu. Od pet glavnih proizvodnih lokacija svih pet je funkcioniralo potpuno samostalno na svojem tržištu. Pred nekoliko godina tvrtka koja je upravo gradila novi pogon A, istovremeno je započela naglu ekspanziju, tako da je kupila tvrtke u sklopu kojih su proizvodni pogoni B, C i D na istom kontinentu te pogon E na drugom kontinentu. Završetkom akvizicijskog ciklusa, tvrtka je počela sa optimizacijom proizvodnih kapaciteta. Glavni razlog za kupovinu drugih tvrtki bila je tržišna pozicija i proizvodni program, a ne proizvodni kapaciteti, što je uzrokovalo višak proizvodnih kapaciteta. Donesena je odluka da se glavnina proizvodnje preseli na lokacije A i C kao najveće i najbolje opremljene. Lokacija B, relativno manja od ostalih ima specifične sposobnosti za određenu vrstu proizvodnje, tako da je odlučeno da se ta lokacija specijalizira za određenu vrstu proizvoda. Za lokaciju D odlučeno je da se proda. Za lokaciju E odlučeno je da zadrži samo dio proizvodnje i to finalni.

6.1.2. Situacija na lokaciji C

Na lokaciji C koja je prepoznata kao jedna od dvije glavne proizvodne lokacije proizvodna linija X iz 1983. godine imala je učestale zastoje. Kako zahtjevi za kapacitetima nisu bili veliki, dotični zastoji nisu uzrokovali kašnjenja proizvoda na tržištu. Kvaliteta proizvoda bila je zadovoljavajuća, ali pojavile su se naznake kako će

kroz dvije godine doći do pooštrenja zahtjeva za osiguranjem kvalitete, te zbog toga dotična linija u ovakvom stanju više neće biti podobna za proizvodnju. Rukovoditelj pogona trebao bi direktoru lokacije predložiti trajnije rješenje situacije sa linijom X.

6.1.3. Situacija sa linijom X

Rukovoditelj pogona na lokaciji C zadužen za proizvodnu liniju X već neko vrijeme smatrao je tu liniju jednim od glavnih problema koji mora riješiti. Već pred dvije godine počeo je predlagati da se nabavi nova linija. Dobio je odgovor kako još nije sigurno hoće li ta vrsta proizvodnje biti zadržana na lokaciji C, te stoga nema smisla investirati u proizvodnju na toj lokaciji. Par mjeseci kasnije rukovoditelju je priopćeno da je lokacija C prema globalnoj strategiji proizvodnje postala jedna od dvije glavne proizvodne lokacije, te se nastavlja proizvodnja svih vrsta proizvoda. Na lokaciju C preselit će se proizvodnja nekih proizvoda iz lokacija B, D i E. Isto tako radi optimizacije doći će do nekih transfera iz lokacije A u C, a isto tako i obratno. Međutim rukovoditelju je poznato da postoji ugovor sklopljen kada je kupovana njegova bivša kompanija prema kojem se neko vrijeme određeni proizvodi moraju proizvoditi na lokaciji C u njegovom pogonu. Nakon redovne interne inspekcije osiguranja kvalitete dobio je izvještaj u kojem se navodi kako određeni dio procesa koji koristi linija X više nije u skladu sa novom regulativom, te da postoji prijelazni period od dvije godine u kojem će moći nesmetano proizvoditi.

Još jednom je krenuo analizirati podatke o liniji na temelju kojih će odlučiti hoće li ponovno uputiti prijedlog da se nabavi nova linija.

6.2. Rješenje na temelju tehničkih informacija-studija slučaja

U nastavku slijedi opis stvarne situacije koja se dogodila godine 2004. Svi korišteni podaci su realni, izostavljeni su neki detalji koji se tiču tajnosti podataka.

6.2.1. Raspoloživi podaci

Podaci koje je rukovoditelj imao na raspolaganju su:

- podaci iz CMMS-a o aktivnostima održavanja liniji X
- planovi prodaje proizvoda koji se rade na liniji X za slijedeće tri godine
- tehnički podaci o linijama koji se nude na tržištu
- novi zahtjevi osiguranja kvalitete

Isto tako poznata mu je strategija tvrtke o konstantnom izbacivanju velikog broja novih proizvoda na tržište, kao i proizvodna strategija koja je odredila da pogon C bude jedan od dva glavna proizvodna pogona u kompaniji. Ta dva podatka upućivala su ga na to kako je investiranje u proizvodnu opremu na lokaciji C usklađeno sa strategijom.

6.2.2. Aktivnosti poduzete prije donošenja odluke

Iz planova prodaje proizvoda koji se proizvode u pogonu C došao je do podatka da će se tijekom slijedeće tri godine maksimalna godišnja potreba biti 1,2 milijuna proizvoda.

Kako se proizvodnja odvijala u dvije smjene, a za potrebe proračuna uzima se da godina ima 220 radnih dana došao je do slijedećih podataka:

$$Potreban_kapacitet = \frac{Ukupna_godišnja_proizvodnja}{Broj_radnih_dana \bullet Broj_sati_u_danu} = \frac{1.200.000}{220 \bullet 16} = 340,9 \frac{kom}{h}$$

Od prikupljenih ponuda odabrao je proizvodnu liniju prosječnog kapaciteta 500 kom/h. Cijena te linije iznosi 700.000€, a troškovi ugradnje i adaptacije priključaka 50.000€.

To znači da će navedena linija imati godišnji kapacitet:

$$Godišnji_kapacitet = Broj_radnih_dana \bullet Broj_sati_u_danu \bullet Prosjecni_kapacitet$$

$$Godišnji_kapacitet = 220 \bullet 16 \bullet 500 = 1.760.000$$

Prema procedurama za investicije potrebno je izraditi financijsku evaluaciju, koju za svaku investiciju ispod 1 milijuna eura radi lokalni odjel financija.

Rezultati financijske evaluacije koja uzima u obzir planiranu proizvodnju, troškove održavanja stare linije, procijenjene troškove održavanja nove linije, potreban broj operatera na staroj i novoj liniji i ukupnu cijenu investicije pokazali su da je nabava takve linija isplativa nakon 3,5 godine. U okviru rezultata financijske analize izdana je preporuka da se investicija odobri.

Rukovoditelj je navedene podatke objedinio u formi standardnog dokumenta "Studija opravdanosti projekta" koji je sadržavao priloge: financijsku evaluaciju i zapisnik osiguranja kvalitete. Navedene dokumente proslijedio je direktoru lokacije C uz prijedlog za nabavu nove linije.

6.2.3. Donošenje odluke

Direktor lokacije C dobio je prijedlog za nabavu nove linije umjesto linije X. Uz prijedlog bila su i tri priloga

- studija opravdanosti projekta nabave i instalacije nove linije
- financijska evaluacija
- primjedba osiguranja kvalitete o novim zahtjevima kvalitete

Na temelju tih informacija i konzultacija sa rukovoditeljem uvrstio je nabavu nove linije u plan investicija za slijedeću godinu.

Nakon nekoliko optimizacija odobren je plan investicija u kojem je ostala stavka od 750.000 € za nabavu i instalaciju nove linije.

6.2.4. Komentar i zaključak

Ovo je opis stvarne situacije koja se dogodila godine 2004. Svi korišteni podaci su realni, izostavljeni su neki detalji koji se tiču tajnosti podataka. Odluka donesena ovom metodologijom i temeljem ovih informacija je logična, tehnički i financijski opravdana.

6.3. *Odluka donesena korištenjem modela uz primjenu poslovne inteligencije*

6.3.1. Uvodni komentar

Slučaj opisan u prethodnoj studiji (vidi poglavlje 6.2) dogodio se u tvrtki koja je tek u početnim fazama implementacije poslovne inteligencije. U ovoj studiji biti će simulirana upotreba poslovne inteligencije kroz dvije bitne razlike u odnosu na prvu studiju slučaja:

- biti će primijenjen model donošenja odluka (vidi poglavlje 5.3.1)
- biti će korištene ostale informacije koje su u vrijeme događaja opisanog u prvoj studiji postojale u drugim dijelovima tvrtke ali nisu korištene zbog nepostojanja sustava poslovne inteligencije

6.3.2. Raspoloživi podaci

Rukovoditelj pogona zadužen za liniju X baratao je slijedećim informacijama standardno dostupnim u operativnim bazama podataka čiji je bio redoviti korisnik.

- podaci iz CMMS-a o aktivnostima održavanja liniji X

- planovi prodaje proizvoda koji se rade na liniji X za slijedeće tri godine
- tehnički podaci o linijama koji se nude na tržištu
- novi zahtjevi osiguranja kvalitete
- layout pogona koji ima na raspolaganju za eventualnu novu liniju

Pored tih informacija kroz sustav poslovne inteligencije bile su mu dostupne slijedeće informacije:

- situacija sa proizvodnim linijama na lokaciji A
- financijski pokazatelji tvrtke
- strategija tvrtke (BSC)
- strategija globalne proizvodnje
- baza planova prodaje svih proizvoda

6.3.3. Postupak donošenja odluke

Kao smjernica za donošenje odluke poslužio mu je slijedeći model:

$$f(ST, TA, OP) = \alpha ST + \beta TA + \gamma OP$$

Rješavanje funkcije utjecaja opisano je u poglavlju 5.3.2, str. 88.

6.3.3.1 Određivanje strateškog dijela funkcije odluke

Najprije se određuje αST (vidi poglavlje 5.3.2.1, str. 89).

ST se određuje tako da se odgovori na pitanje "Da li je nabava nove linije u skladu sa strategijom tvrtke i strategijom proizvodnje?"

Odgovor na to pitanje najlakše je protumačiti iz BSC^{XLIX}-a. U BSC-u za korporaciju postoje samo dva cilja koja se mogu odnositi i na liniju X ili novu liniju koja će je zamijeniti. To je lansiranje novih proizvoda na tržište. Nova linija bi pridonijela bržem izbacivanju većeg broja novih proizvoda na tržište, što znači da u ovom segmentu strategije postoji pozitivan doprinos strategiji.

Drugi dio pitanja odnosi se na usklađenost sa strategijom proizvodnje. U BSC-u "Globalne opskrbe proizvodima" zadan je strateški cilj "Uskladiti proizvodne resurse na raznim lokacijama". U detaljnijem opisu toga cilja definirano je kako "prilikom nabave značajnije nove proizvodne opreme treba uzeti u obzir proizvodne kapacitete na ostalim lokacijama". Iz navedenog je slijedilo da je potrebno pogledati proizvodni kapacitet za tu vrstu proizvoda na lokaciji A.

^{XLIX} BSC-Balanced ScoreCard-Sustav uravnoteženih ciljeva

Uvidom u bazu strojne opreme na lokaciji A pronađen je slijedeći podatak: Za tu vrstu proizvoda postoji linija Y iz 1985. godine, a kapaciteti linije su oko 600 proizvoda na sat. S obzirom na godinu proizvodnje linije postojala je vjerojatnost da koristi istu tehnologiju koja će kroz dvije godine imati regulatornih problema.

U kontaktu sa rukovoditeljem zaduženom za liniju Y ustanovljeno je da se razmatra kupovina nove linije.

Iz toga se slijei odgovor na pitanje o strategiji: *Nije u skladu sa strategijom proizvodnje da se na dvije lokacije kupuju linije za isti tip proizvoda.*

Pošto je za korporativni dio strategije doprinos bio pozitivan, ali je puno veći utjecaj negativnog dijela u strategiji proizvodnje ukupna dodijeljena vrijednost za ST je:

$$ST = -0,7$$

Koeficijent α poprimati će vrijednosti ovisno o odgovoru na pitanje: "Da li nabavom nove linije utječemo na provođenje strategije tvrtke i strategije proizvodnje?"

Kako se u proizvodnom portfoliju tvrtke nalazi velik broj proizvoda, a ova odluka ima utjecaj samo na jedan manji dio, određena je vrijednost za α :

$$\alpha = 0,1$$

Time je završeno određivanje strateškog dijela modela.

6.3.3.2 Određivanje taktičkog dijela funkcije odluke

Taktički dio funkcije odluke određuje se na način kako je prikazano u poglavlju 5.3.2.2 na str. 90.

TA mora odgovoriti na osnovno pitanje: Kako nabava nove linije utiče na financijske rezultate?"

Odgovor na to pitanje daje financijska evaluacija koja je dala pozitivno mišljenje za nabavu nove linije. Ipak pošto će se linija isplatiti tek nakon 3,5 godina rada, dodijeljena je vrijednost

$$TA = 0,5$$

Što se određivanja koeficijenta β tiče, on se određuje odgovorom na pitanje "U kojoj mjeri kupovinom ove linije utječemo na financijske rezultate tvrtke?". Kako se radi o investiciji od 750.000€ određena je vrijednost

$$\beta = 0,3$$

6.3.3.3 Određivanje operativnog dijela funkcije odluke

Operativni dio funkcije odluke određuje se na način kako je prikazano u poglavlju 5.3.2.3 na str. 92.

OP daje odgovor na osnovno pitanje: "Kako će nabava nove linije utjecati na provođenje planova proizvodnje?" Nabava nove linije imat će pozitivan utjecaj na planove proizvodnje zbog velike raspoloživosti koju će imati nova linija u usporedbi sa starom, kao i povećanom kapacitetu u usporedbi sa starom linijom. Zbog toga je određena vrijednost za OP:

$$OP=1$$

Koeficijent γ poprima vrijednost ovisno o odgovoru na pitanje: "U kojoj mjeri nabavom nove linije utječemo na ostvarenje planova proizvodnje?"

U tvrtki postoji relativno veliki broj linija, stoga je određena vrijednost:

$$\gamma=0,1$$

6.3.4. Vrijednost funkcije utjecaja

Kako je $f(ST, TA, OP) = \alpha ST + \beta TA + \gamma OP = 0,1 \cdot (-0,7) + 0,3 \cdot 0,5 + 0,1 \cdot 1 = 0,18$

Prema kriteriju prihvatljivosti, vrijednost funkcije utjecaja od 0,18 zaslužuje preispitivanje i traženje alternative.

6.4. Usporedba rezultata varijanti studije slučaja

U studiji slučaja "Rješenje na temelju tehničkih informacija" (vidi poglavlje 6.2) donesena je odluka o kupnji nove linije umjesto linije X. Odluka donesena ovom metodologijom i temeljem ovih informacija je logična, tehnički i financijski opravdana. Ipak kada su isti podaci, zajedno sa dodatnim podacima čiju dostupnost je omogućila poslovna inteligencija uvršteni u "Model donošenja odluka korištenjem poslovne inteligencije" (vidi poglavlje 6.3) odluka o kupnji nove proizvodne linije više nije bila opravdana, već je tražila alternativno rješenje. Zašto? Upotrebom modela uz podršku poslovne inteligencije otkrivene su bitne činjenice koje mijenjaju situaciju (nabava slične linije nešto većeg kapaciteta na lokaciji A).

6.4.1. Pronađeno alternativno rješenje

U alternativnom rješenju koje se dogodilo u stvarnom životu (kojim je poništena odluka o kupnji linije na lokaciji C) kupljena je jedna linija na lokaciji A čiji je kapacitet

bio 1200 proizvoda na sat, a cijena je iznosila 1,32 milijuna €, dok bi kupnja dvije manje linije iznosila 1,76 milijuna €. Proizvodnja proizvoda koji se rade na liniji X na lokaciji C transferira se na lokaciju A na novu liniju. Osim uštede u cijeni linije, postignuta je ušteda na troškovima radne snage i troškovima održavanja. Navedena ušteda umanjena je za troškove transfera proizvoda.

Tako se optimalno rješenje na temelju tehničkih informacija i ostalih dostupnih kroz operativne baze pokazalo neoptimalnim za tvrtku.

6.5. Testiranje hipoteze studijom slučaja

Hipoteza koja glasi:

"Preduvjet za efikasnije gospodarenje opremom je donošenje odluke na temelju svih informacija, a ne samo onih dostupnih u funkciji održavanja. Poznavanje strategije tvrtke, dugoročnih planova prodaje, planova uvođenja novih proizvoda, međusobno poznavanje resursa i sposobnosti dislociranih proizvodnih lokacija, poznavanje trendova u poslovnom okruženju, te trendova na tržištu.

Sve te informacije sakuplja, obrađuje sustav poslovne inteligencije. Primjenom sustava poslovne inteligencije u gospodarenju tehničkim sustavima, a posebno tehničkim sustavima moguće je donositi kvalitetnije odluke koje će rezultirati racionalnijim gospodarenjem i boljim iskorištenjem resursa tvrtke."

Kroz ovu studiju slučaja hipoteza je potvrđena.

6.6. Kritički osvrt na hipotezu i testiranje hipoteze

Česta je praksa da se hipoteza testira statističkim metodama na velikom broju podataka. To je kvalitetan pristup koji pruža puno povratnih informacija. Hipoteze dokazane na taj način mogu biti argumentirane npr. " u 90% slučajeva pokazalo se".

Kod studije slučaja to nije moguće. Ali nije ni postojala namjera da se ispita koliko često se događa situacija opisana hipotezom. U ovoj studiji slučaja je obrađena jedan od mnogih situacija kada se hipoteza pokazalo točnom. Svrha dokazivanja hipoteze nije bila pokazati kako su odluke koje su donesene bez poslovne inteligencije uvijek manje kvalitetne od drugih, već da postoje situacije kada se odluke razlikuju, te da odluke koje koriste sve relevantne informacije mogu biti povoljnije za tvrtku u cjelini.

6.6.1. Koje se koristi mogu izvući iz ovoga rada?

Što smo dobili dokazivanjem hipoteze i radom u cjelini? Namjera mi potaknuti šire razmišljanje! Naravno ukoliko nemate sustav poslovne inteligencije teško se može izvući korist iz ovoga rada. Ali sustavi poslovne inteligencije sve više se implementiraju u većim tvrtkama. Pokazalo se da veliki broj implementacija nije bio uspješan jer nisu obuhvaćeni svi bitni segmenti poslovanja. Često je bio slučaj da upravo "Gospodarenje tehničkim sustavima" nije bilo uključivano u implementacije sustava poslovne inteligencije. Na taj način ponajprije je nastala šteta u samom gospodarenju tehničkim sustavima, a uz to i cijeli sustav nije zahvatio jedan tako bitan čimbenik uspješnosti poslovanja tvrtke.

Netko može konstatirati da male tvrtke izuzetno uspješno posluju i bez implementiranih sustava poslovne inteligencije. Ta tvrdnja je točna, ali u takvim malim tvrtkama itekako postoji poslovna inteligencija, ali zbog veličine tvrtke ne postoji formalni sustav.

Na primjer vlasnik jedne manje tvrtke izuzetno dobro će znati u kakvom je stanju njegova materijalna imovina. On će donositi strateške, taktičke i operativne odluke i posjedovat će znanja iz sva tri nivoa. Te odluke biti će kvalitetne. Isto tako poznavat će situaciju na tržištu, znati će kako stoje njegovi konkurenti, i koristit će sve formalne i neformalne izvore informacija. Isto tako neće mu biti potrebni formalni modeli za donošenje odluka, jer će cijelo vrijeme imati u glavi pregled cjelokupne situacije.

Kod velikih tvrtki je problem što jedna osoba (ili manji broj osoba) jednostavno nije uključena u sve aktivnosti, štoviše svatko je uključen u jedan izuzetno mali dio poslovnih aktivnosti tvrtke. Naravno da postoje linije izvještavanja, ali predsjednik uprave tvrtke od pet tisuća zaposlenih znati će za konkretnu situaciju u proizvodnji, tek ako ona uzrokuje veliki problem za cijelu tvrtku. U normalnim situacijama sigurno neće biti upoznat sa detaljima. Problem može nastupiti kada se velika tvrtku pokušava voditi na način kako to funkcionira kod male, bez implementiranog sustava poslovne inteligencije. Ono što treba omogućiti sustav poslovne inteligencije i modeli donošenja odluka je to velika tvrtka funkcionira poput male, to jest da su kod donošenja odluka uključene sve informacije.

Već je ranije navedeno da se cijena implementacije skladišta podataka koje je osnovna komponenta sustava poslovne inteligencije kreće od 200.000 do 1 milijun dolara. Ovako rastezljiva brojka rezultat je raznolikog opsega implementacije. Česta

je situacija da se krene sa minimalnom varijantom koja onda ne pruža željene rezultate. U ovom opsegu rada nije moguće preciznije odrediti kolika je cijena uključivanja područja gospodarenja tehničkim sustavima u implementaciju, to će naravno ovisiti o konkretnim slučajevima.

Nadam se će ovaj rad donijeti svoj doprinos kada dođe u ruke osobi koja se bavi uvođenjem sustava poslovne inteligencije u svoju tvrtku, i da će barem kritički razmisliti, izraditi simulacije i proračune kako bi dobio odgovor na pitanje "Kolika može biti konkretna korist od uključivanja gospodarenja tehničkim sustavima u sustav poslovne inteligencije?".

7. ZAKLJUČAK

Tijekom rada u održavanju, kasnije u korporativnoj strategiji, i na kraju u gospodarenju imovinom često sam bio suočen sa problemom nedostupnosti informacija potrebnih za donošenje odluke. Još gora situacija od one kada informacije nisu dostupne, bila je situacija kada nisam ni znao da takve informacije postoje. Kako sam stjecao iskustvo i radio u raznim dijelovima tvrtke uspijevao sam dolaziti do informacija zahvaljujući svojem poznavanju funkcioniranja velike tvrtke, kao i osobnom poznavanju ljudi koji su "posjedovali" određene informacije bitne za uspješno obavljanje moga posla. Ponekad sam se pitao u kojoj mjeri je uspješno implementiran ERP sustav (SAP) kada neke informacije nisu međusobno povezane, a sve su u istom sustavu. Dobivao sam saznanja da velike SW tvrtke koje prodaju ERP sustave počinju nuditi "Data Warehouse" kao rješenje tih problema. Obrazloženje je bilo u tome da su ERP sustavi operativne baze podataka i da usprkos tome što su pojedini moduli dio integralnog sustava, nije uvijek moguće uspostaviti vezu i otkriti međusobne utjecaje između pojedinih dijelova tvrtke. Kada je počela implementacija Data Warehousea u tvrtki kojoj radim, uočio sam da opet nisu uključeni svi dijelovi i da je cijela implementacija ima parcijalan cilj koji je u domeni financija, a ne cijele tvrtke. To me je navelo da istražim u kojoj mjeri jedan takav alat koji je osnovni dio infrastrukture sustava poslovne inteligencije u tvrtki može doprinijeti kvalitetnijem i jednostavnijem obavljanju moga posla.

Tijekom istraživanja stanja u gospodarenju tehničkim sustavima ustanovio sam da su pojedini autori uočili važnost povezanosti gospodarenja tehničkim sustavima sa ostalim funkcijama u tvrtki. Isto tako postoje i alati (npr. BSC) čija je karakteristika upravo povezivanje strategije sa operativom i harmonizacija ciljeva između pojedinih funkcija u organizaciji.

Iako sam imao pozitivna iskustva sa BSC-om došao sam do zaključka kako nedostaje informacijska poveznica između pojedinih nivoa, a pogotovo horizontalno. Ispravno implementiran sustav poslovne inteligencije pruža tu kariku koja nedostaje. Mnoge implementacije pojedinih dijelova infrastrukture sustava poslovne inteligencije nisu donijele očekivane rezultate zato jer se prilikom definiranja ciljeva, pa i tijekom same implementacije nije sagledala cjelina.

Postavio sam pitanje kakvu koristi može donijeti implementacija sustava poslovne inteligencije u gospodarenju materijalnom imovinom a pogotovo tehničkim sustavima?

Da bi odgovorio na pitanje bilo je potrebno otkriti koje su to "slabe točke" u sustavu gospodarenja tehničkim sustavima. Kako u Hrvatskoj još uvijek odgovornost za tu funkciju snosi funkcija održavanja provedena je anketa o percepciji funkcije održavanja od strane višeg menadžmenta. Korištena je anketa iz [31] (The handbook of Maintenance Management).

Rezultati su pokazali da se radi o nedovoljnoj povezanosti funkcije održavanja sa strategijom, lošem sustavu izvještavanja te nepostojanju budžeta za unapređenja. U nastavku rada nastojao sam pronaći rješenja za prva dva problema čime bi se indirektno i olakšalo rješavanje trećega.

Jedan od načina da dođem do odgovora bilo je ispitati da li će se razlikovati odluke donesene samo na temelju tehničkih i operativnih informacija od onih odluka u koje su uključene i sve ostale informacije. Moja pretpostavka bila je da će postojati razlika! Da bi ispitao svoju pretpostavku kreirao sam jednostavan, ali obuhvatan model koji će omogućiti takvo testiranje na situacijama koje su se već dogodile. Osnovni pristup u modelu je uključiti sve nivoe upravljanja tvrtkom sa informacijama koje se koriste primarno na određenim nivoima. Primijenjena je podjela na strateški, taktički i operativni dio. Na toj podjeli baziran je i model donošenja odluka. Pretpostavka je da za optimalno odlučivanje moraju biti uključeni i evaluirani svi nivoi upravljanja.

U studiji slučaja odabrana je situacija odluke o nabavi proizvodne linije koja je bila korektna na nivou na kojem je evaluirana. Kada je isti problem rješavan kroz model odlučivanja, za čiju je ispravnu upotrebu neophodan neki oblik sustava poslovne inteligencije, rješenje se pokazalo različitim od postojećeg. Na taj način upotrebom modela, na navedenom slučaju dokazano je da se odluke donesene na temelju raznih opsega informacija razlikuju preko čega je i potvrđena hipoteza ovoga rada.

Kroz potvrdu hipoteze dobio sam i odgovor na pitanje postavljeno na početku bavljenja ovom problematikom. *"Poslovna inteligencija može doprinijeti boljem gospodarenju tehničkim sustavima odnosno materijalnom imovinom općenito."*

Pitanje koje je neophodno postaviti kod svakog znanstvenog rada je: "Kakvu korist može donijeti ovaj rad?"

U današnje vrijeme sustavi poslovne inteligencije se masovno implementiraju u razvijenim gospodarstvima i uspješnim tvrtkama. Pojedine hrvatske tvrtke prate takve

trendove ponekad možda i nekritički bez pravilno definiranih ciljeva. Ovim radom je pokazano kako poslovna inteligencija može dati doprinos uspješnijem gospodarenju tehničkim sustavima, a time posredno i boljoj konkurentskoj poziciji tvrtke u cjelini. Osim uspješnijeg gospodarenja tehničkim sustavima gdje se vidi direktna korist, pretpostavka da će se dogoditi sinergijski efekti i kod ostalih funkcija zbog raspoloživosti informacija o gospodarenju tehničkim sustavima. Otkrivanje sinergija je izuzetno kompleksan problem i može biti slijedeći korak u istraživanju, uz korištenje alata Data Mininga, a pogotovo Bayesovih mreža povjerenja.

8. KORIŠTENJA LITERATURA

-
- [1] R. Kaplan, D. Norton, "Strategy Maps: Converting Intangible Assets into Tangible Outcomes", Harvard Business School Press, Boston, 2001
- [2] <http://www.scip.org>
- [3] Skupina Autora, "Temelji računovodstva i analitička knjigovodstva", RRIF Plus, Zagreb, 2004
- [4] J.S. Mitchell, "Physical Asset Management Handbook", Clarion Technical Publishers, Houston, 2002.
- [5] www.mt-online.com, J. Moubray, "21st Century Maintenance Organization Part I: The Asset Management Model"
- [6] A. Wilson, "Asset Maintenance Management", Industrial Press Inc. New York, 2002
- [7] L. Hagberg, Hautanen S, Henriksson T, "Keep it Running-Industrial Asset Management", SCEMM, Painoyhtymä Oy, 1998
- [8] P. Wilmott, "Total Productive Maintenance", Butterworth-Heinemann, Oxford, 1997
- [9] S.S Blanco, "Integral Maintenance Optimization IMO", The 16th International Maintenance Conference, Euromaintenance 2002, Helsinki, 2002, str. 224.-225.
- [10] B. S Blanchard, "Design and Manage to Life Cycle Cost", M/A Press, Forest Grove, 1978
- [11] H.P Barringer, D.P. Weber, "Life Cycle Cost Tutorial", Fifth International Conference on Process Plant Reliability, Houston, 2.-4.10.1996. Gulf Publishing Company
- [12] www.mt-online.com, J. Moubray, "The maintenance mission"
- [13] www.mt-online.com, J. Moubray, "Developing A Maintenance Strategy"
- [14] Skupina autora, "Održavanje opreme" Inženjerski priručnik IP4" poglavlje 9, Školska knjiga, Zagreb, 2002
- [15] S. Nakajima, "Introduction to TPM", Productivity Press, Cambridge, 1988
- [16] R. Kaplan, D. Norton, "The Strategy Focused Organization", Harvard Business School Press, Boston, 2000

- [12] T. Pyzdek, "The Six Sigma Handbook", McGraw Hill Companies, New York, 2003
- [18] B. Gilad, "Business Blindspots", Probus Professional Pub, Boston, 1993
- [19] A. S. Hornby, "Oxford Advanced Learners Dictionary", Oxford University Press, Oxford 2004
- [20] Ž. Panian, G. Klepac, "Poslovna inteligencija", Masmedia, Zagreb, 2003
- [21] L. Moss, t.. Atre, "Business Intelligence Roadmap", Addison-Wesley, Boston 2003
- [22] L. Kahaner, "Competitive intelligence", A Touchstone books, New York, 1997
- [23] R. Kimball, "The Data Warehouse Toolkit", John Wiley & Sons, Indianapolis, 2004
- [24] www.dwinfocenter.org, L. Greenfield, "The Case for Data Warehousing",
- [25] M. Corey, M. Abbey, I. Abramson, B. Taub, "Oracle 8i Data Warehousing", McGraw-Hill, Berkeley, 2001
- [26] E. Brethenoux, H. Dresner, K. Strange, "Strategic Analysis Report", Gartner Group, 1996
- [27] E. Brethenoux, H. Dresner, K. Strange, J." Data Warehouse, Data Mining and Business Intelligence: The Hype Stops Here", GartnerGroup RAS Services, 1996
- [28] <http://ai.stanford.edu/people/nilsson/mlbook.html>, N. J. Nilson, "Introduction to Machine Learning"
- [29] <http://www.cra.com/>, Charles River Analytics, "About Bayesian Belief Network"
- [30] S. Russel, P. Norvig, "Artificial Intelligence: A Modern Approach", Prentice-Hall, Engelwood Cliffs, 1995
- [31] J. Levitt, "The Handbook of Maintenance Management", Industrial Press Inc., New York, 1997

ŽIVOTOPIS

Rođen sam 18. 06. 1971 u Zagrebu. Živim u Jastrebarskom gdje sam završio i osnovnu školu. Od 1986-1990 pohađao sam srednju školu, MIOC u Zagrebu.

Godine 1991 upisao sam studij Strojarsstva na Fakultetu strojarstva i brodogradnje u Zagrebu gdje sam i diplomirao 1997 na zavodu za industrijsko inženjerstvo. Tema diplomskog rada bila je "Organizacijsko i aplikativno rješenje preventivnih pregleda" na primjeru Plive d.d.

Nakon završetka studija 1997 započinjem raditi na Fakultetu strojarstva i brodogradnje u Zagrebu na zavodu za industrijsko inženjerstvo kao suradnik na projektima. Tijekom rada na fakultetu surađivao sam na projektima za slijedeće tvrtke ili organizacije: Pliva d.d, HV, Državni zavod za normizaciju i mjeriteljstvo.

U Plivu prelazim 1998 gdje sam radio na raznim pozicijama, od Održavanja farmaceutskih proizvodnih pogona, korporativne strategije do Gospodarenja imovinom i strategije proizvodnje.

Tijekom svoga rada u Plivi pohađao sam brojne inozemne edukacije iz raznih područja (opći menadžment, poslovna inteligencija, menadžment proizvodnje, interni konzalting, financije, prezentacijske vještine itd.)

Objavio sam šest znanstvenih i jedan stručni rad. Služim se engleskim jezikom. Nisam oženjen.

CURRICULUM VITAE

I was born on 18. 06. 1971 in Zagreb. I live in Jastrebarsko where I have finished my primary education. During 1986-1990 I have completed my secondary education MIOC in Zagreb.

In 1991 I start studying at Faculty of Mechanical Engineering and Naval Architecture in Zagreb where obtained degree in 1997 at "Department for Industrial Engineering". The subject of my final work was "Organization and SW Application for Preventive Maintenance " on example of Pliva d.d.

In 1997 I start to work at Faculty of Mechanical Engineering and Naval Architecture at Department for Industrial Engineering as associate. During my work on Faculty I was member of several projects including Pliva, Croatian Army and Croatian Metrology Institute.

In 1998 I start to work in Pliva d.d. where I have several different positions from maintenance department, Corporate Strategy, and Asset Management & Production Strategy. I have attended numerous educations outside Croatia from many different areas (General Management, Business Intelligence, Manufacturing Management, Internal Consulting Skills, Finance, International Presentation Skills etc.)

I have published five scientific articles and one specialistic. I have fluent knowledge of English language. I'm single.